

UNIVERSITE de CAEN/BASSE-NORMANDIE

U.F.R.: Sciences

ECOLE DOCTORALE SIMEM

THESE

Présentée par

Mr Cyril Meurie

et soutenue

le 25 octobre 2005

en vue de l'obtention du

DOCTORAT de l'UNIVERSITE de CAEN

Spécialité : Informatique

(Arrêté du 25 avril 2002)

**TITRE : Segmentation d'images couleur
par classification pixellaire et
hiérarchie de partitions**

MEMBRES du JURY

Mr Abderrahim Elmoataz, Professeur, Université de Caen Basse-Normandie Directeur de Thèse
Mme Christine Fernandez-Maloigne, Professeur, Université de Poitiers Rapporteur
Mr Pierre Gouton, Professeur, Université de Bourgogne Rapporteur
Mr Hubert Cardot, Professeur, Université François-Rabelais de Tours Examineur
Mr Olivier Lezoray, Maître de Conférences, Université de Caen Basse-Normandie Examineur
Mme Marinette Revenu, Professeur, ENSICAEN, Université de Caen Basse-Normandie Examineur

Remerciements

Ce travail de recherche a été réalisé au sein de l'équipe Vision et Analyse d'Image (VAI) du Laboratoire Universitaire des Sciences Appliquées de Cherbourg (LUSAC). Ce travail de recherche a été financé par une allocation MENRT.

Je remercie Christine Fernandez-Maloigne, Professeur à l'université de Poitiers et Pierre Gouton, Professeur à l'université de Bourgogne pour avoir gentiment accepté d'être rapporteurs de cette thèse et de participer à mon jury.

Je tiens à remercier Hubert Cardot, Professeur à l'université de Tours pour m'avoir accueilli dans le groupe Vision et Analyse d'Images (VAI) du LUSAC et m'avoir proposé ce sujet de thèse à l'époque où il était Maître de Conférence à l'université de Caen Basse-Normandie, et accepté de participer à mon jury.

Je remercie Marinette Revenu, Professeur à l'ENSICAEN pour avoir accepté de participer à mon jury.

Je remercie Jean-Marie Haussonne, Professeur à l'université de Caen Basse-Normandie et Directeur du LUSAC jusqu'en février 2005 ainsi que Bertrand Boudart, Professeur à l'université de Caen Basse-Normandie et Directeur du LUSAC depuis février 2005 pour m'avoir accueilli au sein du laboratoire.

Je tiens à remercier Abderrahim Elmoataz, Professeur à l'université de Caen Basse-Normandie pour avoir dirigé mon doctorat et guidé mes recherches.

J'exprime toute ma gratitude à Olivier Lezoray, Maître de Conférence à l'université de Caen Basse-Normandie pour avoir co-dirigé cette thèse. Ses conseils, critiques, encouragements et sa confiance m'ont permis de mener à bien ce travail de recherche. Il a été pour moi plus qu'un co-directeur de thèse et je tiens à le remercier profondément.

Je remercie Christophe Charrier, Maître de Conférence à l'université de Caen Basse-Normandie pour avoir toujours été disponible et pour avoir effectué une relecture de la version préliminaire de ce manuscrit.

Je tiens à remercier Hubert Elie, Docteur et Chef du service d'anatomie et cytologie pathologique du centre hospitalier Louis Pasteur de Cherbourg-Octeville pour m'avoir accueilli dans ses locaux et proposé le domaine d'application de cette thèse plus qu'intéressant. Je tiens à ajouter à ces remerciements Michel Lecluse, Cyto-technicien de laboratoire, pour avoir tous deux passé un temps non négligeable à la création d'une base de segmentation de référence.

Je remercie Philippe Belhomme, Maître de Conférence à l'université de Caen Basse-Normandie pour sa sympathie et pour avoir effectué une relecture de la version prélimi-

naire de ce manuscrit.

Je tiens à remercier mes autres collègues : Gilles Lebrun, Lionel Garnier, Anthony Paul avec qui j'ai passé de bons moments qu'ils soient professionnels ou extra professionnels.

Je remercie tous les membres de l'équipe Vision et Analyse d'Image, du département SRC et GIM de l'IUT Cherbourg-Manche pour leur sympathie et les moments de détente que j'ai pu partager.

Enfin, je remercie ma famille et mes amis pour m'avoir soutenu et supporté pendant ces années de thèse.

TABLE DES MATIÈRES

1	Introduction générale	1
I	Segmentation d'images couleur par classification pixellaire	5
2	La représentation de la couleur	7
2.1	Images microscopiques de cytologie bronchique	7
2.1.1	Paramètres du microscope	8
2.2	Les différents modèles de représentation de la couleur	9
2.3	Les espaces de représentation couleur	10
2.3.1	Les systèmes de primaires	10
2.3.1.1	L'espace RGB	10
2.3.1.2	L'espace XYZ	12
2.3.1.3	L'espace CMY	14
2.3.2	Les espaces luminance-chrominance	15
2.3.2.1	l'espace AC_1C_2	15
2.3.2.2	L'espace YCh_1Ch_2	15
2.3.2.3	L'espace YUV	16
2.3.2.4	L'espace YIQ	16
2.3.2.5	L'espace YC_bC_r	16
2.3.2.6	L'espace $L^*u^*v^*$	17
2.3.2.7	L'espace L^*a^*b	17
2.3.3	Les systèmes perceptuels	19
2.3.3.1	L'espace $L^*C^*H^*$	19
2.3.3.2	L'espace HSL	20
2.3.3.3	L'espace $IHSL$	21
2.3.4	Les système d'axes indépendants	21
2.3.4.1	L'espace $I_1I_2I_3$	21
2.4	Synthèse des différents espaces couleurs	22

2.5	Conclusion	26
3	Segmentation d'images couleur	27
3.1	La classification pixellaire	28
3.1.1	Définition d'un classifieur	28
3.1.2	Classification à partir d'histogrammes 1D, 2D et 3D	29
3.1.3	Classification par clustering	31
3.1.4	Classification de pixels non supervisée	31
3.1.4.1	Algorithme des k-moyennes	32
3.1.4.2	Algorithme des C-moyennes floues	34
3.1.4.3	Algorithme de Fisher	36
3.1.5	Classification de pixels supervisée	36
3.1.5.1	Algorithme des k-plus proches voisins	37
3.1.5.2	Algorithme de Bayes	37
3.1.5.3	Algorithme des Machines à support de vecteurs	39
3.1.5.4	Algorithme des Réseaux de Neurones Multi Couches	39
3.1.6	Précautions liées à l'utilisation de la classification pixellaire	40
3.1.7	Classification spatio-colorimétrique des pixels	42
3.2	Construction de régions	44
3.2.1	Méthodes ascendantes	44
3.2.2	Méthodes structurelles	45
3.2.2.1	Approche division-fusion de régions	45
3.2.2.2	Approche fusion de régions	46
3.2.3	Coopération régions-contours	46
3.3	Conclusion	47
4	Évaluation de la segmentation	49
4.1	Évaluation sans vérité terrain	49
4.1.1	Critère d'uniformité intra-région de LEVINE ET NAZIF	50
4.1.2	Contraste inter-région de LEVINE ET NAZIF	50
4.1.3	Contraste de ZEBOU DJ	50
4.1.4	Mesure de dissimilarité de LIU ET YANG	51
4.1.5	Critère de BORSOTTI ET AL	51
4.2	Évaluation avec vérité terrain	52
4.2.1	La vérité terrain	52

4.2.2	Mesure de MARTIN	55
4.2.3	Mesure de YASNOFF ET AL	56
4.2.4	Mesure de VINET	56
4.2.5	Une méthode d'évaluation adaptée à la cytologie	57
4.3	Conclusion	61
5	Une approche hybride de segmentation d'images couleur	63
5.1	Simplification de l'image	63
5.2	Classification pixellaire non supervisée	64
5.2.1	Classification pixellaire non supervisée en une étape	65
5.2.2	Classification pixellaire non supervisée en deux étapes	70
5.3	Classification de pixels supervisée	75
5.4	Combinaison de classifications pixellaires	79
5.4.1	Indice de confiance	81
5.4.2	Les méthodes de combinaison sans apprentissage	82
5.4.3	Méthodes de combinaison avec apprentissage	85
5.5	Intégration dans une approche morphologique	87
5.5.1	Simplification de l'image	89
5.5.2	Filtrage morphologique des marqueurs	89
5.5.3	Ligne de Partage des Eaux couleur	90
5.6	Conclusion	92
II	Segmentation d'images couleur par hiérarchie de partitions	95
6	Méthodes pour une segmentation hiérarchique	97
6.1	Différents modèles de structuration d'image	97
6.1.1	Pyramides régulières	97
6.1.1.1	Pyramide gaussienne et laplacienne	97
6.1.1.2	L'arbre quaternaire	98
6.1.2	Pyramides irrégulières	99
6.1.2.1	Graphe de frontières de régions	100
6.1.2.2	Graphe d'adjacence de régions	100
6.1.2.3	Construction d'une pyramide de graphes	101
6.1.2.4	Cartes combinatoires	104
6.2	Méthodes morphologiques	104

6.2.1	Zone plate et quasi-plate	106
6.2.2	Connexion par sauts	108
6.2.3	Ligne de Partage des Eaux	108
6.2.4	Fusion de régions dans un treillis	111
6.3	Conclusion	117
7	De nouvelles approches hiérarchiques	119
7.1	Zones homogènes	120
7.2	Morphologie mathématique couleur	124
7.2.1	Une nouvelle approche basée sur un graphe	126
7.2.2	Gradient morphologique couleur	130
7.2.3	Hiérarchie de segmentations par waterfall	131
7.3	Simplification et segmentation d'image par lissage non linéaire d'un graphe et fusion de régions	133
7.3.1	Hiérarchie de partitions par fusion de régions	137
7.4	Evaluation d'une hiérarchie de partitions	140
7.4.1	Une mesure d'énergie	143
7.5	Simplification d'une partition par fusion de régions	150
7.6	Berkeley Segmentation Dataset and Benchmark	153
7.7	Conclusion	155
8	Conclusion générale et perspectives	159
9	Publications de l'auteur	163
	Bibliographie	167
A	Perception humaine de la couleur	181
A.1	La source lumineuse	182
A.2	Le matériau	183
A.3	Le récepteur humain : l'oeil	183
A.4	Le système d'interprétation : le cerveau	184

TABLE DES FIGURES

1.1	Projet d'une station d'analyse de microscopie automatisée pour la cytopathologie.	2
2.1	Images microscopiques de cytologie bronchique.	8
2.2	Décomposition d'une image RGB de la « Berkeley Segmentation Dataset and Benchmark » [BERKEL] selon les trois composantes R , G , et B	10
2.3	La représentation spatiale du modèle RGB	11
2.4	Variation du tri-stimulus RGB en fonction de la longueur d'onde.	12
2.5	Variation du tri-stimulus XYZ en fonction de la longueur d'onde.	13
2.6	Le diagramme de chromaticité (x, y) de la CIE.	14
2.7	La représentation spatiale du modèle $L^*a^*b^*$	18
2.8	La représentation spatio-colorimétrique du modèle HSL	20
2.9	Schéma des différentes familles d'espaces de représentation couleur, inspiré de celui de VANDENBROUCKE [VANDEN00]	23
2.10	Représentation de l'image couleur dans différents espaces couleur effectuée à l'aide du logiciel « ColorSpace » (http://www.couleur.org/).	24
2.11	Image dans différents espaces de représentation couleur.	25
2.12	Image re-colorisée après une quantification en 16 couleurs de l'image couleur par l'algorithme des k-moyennes et dans différents espaces de représentation couleur.	25
3.1	Quantification en 4 couleurs avec différents algorithmes de classification de pixels non supervisés.	32
3.2	Approche de l'apprentissage.	33
3.3	Visualisation du nombre de classes.	34
3.4	Représentation d'une image dans l'espace RGB	34
3.5	Classification pixellaire par l'algorithme des k-moyennes.	35
3.6	Classification pixellaire par l'algorithme de Fisher sur la composante L de l'espace HSL	36
3.7	Classification pixellaire par l'algorithme des k-PPV.	38
3.8	Classification pixellaire par l'algorithme de Bayes.	38
3.9	Classification pixellaire par l'algorithme des SVM.	40

3.10	Classification pixellaire par l'algorithme des RNMC.	41
3.11	Résultats de plusieurs classifications pixellaire par l'algorithme des k-moyennes avec un nombre de classes différent pour chaque image.	42
3.12	Quatre images d'une base d'apprentissage en imagerie microscopique biomédicale ((a) du mucus diffus et un groupement de cellules, (b) des cellules diverses, (c) une présence de globules rouges et des débris, (d) une forte concentration de mucus).	43
3.13	Quatre images d'une base de tests en imagerie microscopique biomédicale.	43
4.1	Concordance entre plusieurs segmentations de référence produites par différents experts.	53
4.2	Création d'une segmentation de référence pour une image cytologique.	54
4.3	Quatre segmentations de référence d'une base d'apprentissage.	55
4.4	Résultats de différentes évaluations sur la segmentation d'une image par l'algorithme de Bayes ((a) l'image initiale, (b) la vérité terrain, (c-d) deux images segmentées.)	60
5.1	Exemple de simplification d'image : ((a) une image de la base de tests, (b) image simplifiée avec l'attache aux données, (c) image simplifiée avec l'attache aux données, la diffusion et la réaction).	65
5.2	Principe de la classification pixellaire en une étape.	66
5.3	Illustration du principe de classification pixellaire en une étape retenu.	69
5.4	Principe de la classification pixellaire en deux étapes.	70
5.5	Illustration du principe de classification pixellaire en deux étapes.	74
5.6	Influence de l'espace de représentation couleur pour une classification pixellaire effectuée par l'algorithme des SVM avec 334 exemples.	76
5.7	Influence de l'espace de représentation couleur pour une classification pixellaire effectuée par l'algorithme des SVM avec 1002 exemples.	76
5.8	Influence de l'espace de représentation couleur pour une classification pixellaire effectuée par l'algorithme des k-PPV avec 334 exemples.	77
5.9	Influence de l'espace de représentation couleur pour une classification pixellaire effectuée par l'algorithme des k-PPV avec 1002 exemples.	77
5.10	Influence de l'espace de représentation couleur pour une classification pixellaire effectuée par l'algorithme de Bayes.	78
5.11	Influence de l'espace de représentation couleur pour une classification pixellaire effectuée par l'algorithme des RNMC.	78
5.12	Résultats des différentes classifications pixellaires pour une image de la base de tests et (j) les zones d'incohérence (de couleur jaune).	80
5.13	Schéma des méthodes de combinaison parallèle de classifieurs inspiré de celui de ZOUARI [ZOUARI02].	81

5.14	Influence de la règle de combinaison sur la reconnaissance du cytoplasme, en fonction du nombre de classifications pixellaires combinées.	84
5.15	Influence de la règle de combinaison sur la reconnaissance du noyau, en fonction du nombre de classifications pixellaires combinées.	84
5.16	Influence du nombre de voisins sur la reconnaissance du cytoplasme, en fonction du nombre de classifications pixellaires combinées.	85
5.17	Influence du nombre de voisins sur la reconnaissance du noyau, en fonction du nombre de classifications pixellaires combinées.	86
5.18	Stratégie de segmentation d'images 2D couleur.	88
5.19	Zones d'incertitude sur les deux types d'objets à segmenter.	90
5.20	Quatre images de la base de tests segmentées.	91
6.1	Multi résolution obtenue par réduction de la taille de l'image.	98
6.2	Principe de découpage de l'arbre quaternaire.	99
6.3	Multi résolution obtenue par simplification de l'image.	100
6.4	Graphe des frontières de régions.	101
6.5	Notations et Graphe d'Adjacence de Régions.	101
6.6	Graphe d'Adjacence de Régions.	102
6.7	Exemple d'un processus de décimation [LALLIC03].	102
6.8	Exemple de graphe et d'un noyau de contraction ((a) : graphe G_0 , (b) : noyau de contraction $N_{0,1}$, (c) : contraction des arêtes $G_0/N_{0,1}$) [KROPAT95].	103
6.9	Pyramide de graphe avec noyau de contraction [KROPAT95].	103
6.10	Exemple d'une carte combinatoire et de son graphe dual.	104
6.11	Zones plates et quasi-plates d'une image ((a) les zones plates puis (b-d) quasi-plates de l'image et (e-h) leurs images mosaïques respectives). . . .	107
6.12	(a) Connexion par saut de la composante rouge d'une image ((b-d) les connexions par sauts aux valeurs d'amplitude λ , (e) l'image couleur initiale, (f-h) images mosaïques des différents connexions par sauts aux valeurs d'amplitude λ).	109
6.13	Hierarchie de partitions par l'algorithme de waterfall ((a-d) l'image découpée en régions par l'algorithme de waterfall, (e-h) l'image mosaïque respective).	110
6.14	Simplification du Graphe d'Adjacence de Régions (à gauche : le RAG initial et à droite : le RAG obtenu après fusion de deux régions).	112
6.15	Exemple de création d'un arbre binaire de partitions avec un algorithme de fusion de régions ((a) l'image initiale découpée en 7 régions, puis (b-d) respectivement cette même image avec une fusion de régions deux à deux, (e-g) suivie de la représentation de ces fusions par un arbre binaire de partitions).	114

6.16	Exemple d'un arbre binaire de partitions sur une image.	115
7.1	Partitions par zones homogènes de finesses décroissantes ((a-d) : régions, (e-h) : mosaïques correspondantes).	121
7.2	Hiérarchies de partitions par (1 ^{ère} ligne) LPE, (2 ^{ème} ligne) zones quasi-plates, (3 ^{ème} ligne) connexions par sauts et (4 ^{ème} ligne) par zones homogènes stratifiées.	123
7.3	Exemple d'érosion couleur basée sur un ordre lexicographique.	126
7.4	Processus de décimation du MST du graphe de voisinage (de gauche à droite, le RAG G_0 et les MST successifs G_i avec $i \in [1, 4]$).	127
7.5	Comparaison entre une approche lexicographique et une approche par graphe sur une érosion et une dilatation.	129
7.6	Exemple de l'influence de la couleur de référence (noire, rouge, verte, bleue, jaune) sur une érosion.	130
7.7	Exemples de gradients couleur.	131
7.8	Résultats de segmentations obtenues avec l'algorithme du waterfall et différents gradients couleur.	133
7.9	Hiérarchie de partitions obtenues (niveaux 0, 3, 5, 7, 9) avec l'algorithme de waterfall et différents gradients couleur ($\nabla_{\vee} f$ lex : 1 ^{ère} ligne, $\nabla_{\vee} f$: 2 ^{ème} ligne, $\nabla_{L_2} f$: 3 ^{ème} ligne, $\nabla_{L_1} f$: 4 ^{ème} ligne, $\nabla_{PC} f$: 5 ^{ème} ligne). . .	134
7.10	Ensemble d'images simplifiées dans un schéma espace-échelle sur graphe après 0, 5, 60 et 200 itérations du filtre de lissage ((a-d) : graphe, (e-h) : arbre de recouvrement minimum).	136
7.11	Hiérarchie de partitions produite par l'approche proposée pour une partition fine par zones plates (niveaux 1, 3, 5, 7, 9, 11, 13), LPE (niveaux 1, 3, 5, 7, 9, 11, 13) et zones homogènes de finesse $k = 1$ (niveaux 1, 3, 4, 6, 8, 10, 11).	139
7.12	MSE des hiérarchies de la figure 7.11.	140
7.13	Hiérarchies de partitions produites par l'approche proposée pour une partition fine par zones homogènes de finesse $k = 1$ (niveaux 1, 3, 4, 6, 8, 10, 11) sans variation du seuil de fusion.	141
7.14	Variation des différents paramètres de l'énergie dans la production d'une hiérarchie.	145
7.15	Hiérarchie de partitions obtenue avec l'approche par classique du waterfall (niveaux 0 à 18).	148
7.16	Influence du choix de la distance dans la mesure d'énergie pour l'évaluation d'une hiérarchie de partitions produite par waterfall (modèle gaussien).	149
7.17	Influence du choix de la distance dans la mesure d'énergie pour l'évaluation d'une hiérarchie de partitions produite par waterfall (modèle constant).	149

7.18	Application de la méthode d'évaluation sur une hiérarchie de partitions produite par deux des approches proposées : le waterfall avec une approche par graphe et un lissage non linéaire d'un graphe et fusion de régions.	151
7.19	Application de la méthode d'évaluation sur une hiérarchie de partitions produite par deux des approches proposées : les zones homogènes non stratifiées et stratifiées.	152
7.20	Détermination de la meilleure partition obtenue par fusion de régions par rapport à une distance inter-classe et un modèle (constant (c-g) ou gaussien (h-l)) et une approche par graphe.	153
7.21	Détermination de la meilleure partition obtenue par fusion de régions par rapport à une distance inter-classe et un modèle (constant (c-g) ou gaussien (h-l)) et une approche par arbre de recouvrement minimum.	154
7.22	Résultats de cinq méthodes de segmentation sur une première série d'images de la BSDB (de haut en bas : l'image initiale, la segmentation de référence et cinq méthodes de segmentation que nous avons précédemment identifiées sous le nom de « méthode 1 » à « méthode 5 »).	156
7.23	Résultats de cinq méthodes de segmentation sur une deuxième série d'images de la BSDB (de haut en bas : l'image initiale, la segmentation de référence et cinq méthodes de segmentation que nous avons précédemment identifiées sous le nom de « méthode 1 » à « méthode 5 »).	157
A.1	La perception humaine de la couleur.	181
A.2	Spectre des couleurs.	182
A.3	L'oeil humain.	184

INTRODUCTION GÉNÉRALE

Motivation

Une partie des travaux de recherche présentés dans ce manuscrit s’inscrit dans le cadre général d’un projet mené par le groupe Vision et Analyse d’Images (VAI) du Laboratoire Universitaire des Sciences Appliquées de Cherbourg (LUSAC) et le Service d’Anatomie et de Cytologie Pathologique du Centre Hospitalier Louis Pasteur de Cherbourg. Ce projet consiste à élaborer une station d’analyse de microscopie automatisée pour la cytopathologie afin d’améliorer le contrôle qualité en imagerie microscopique pour la santé en assistant l’évaluation visuelle.

Les cyto-pathologistes tout comme les médecins d’autres spécialités médicales, ont une démarche diagnostique essentiellement basée sur l’analyse visuelle d’images microscopiques. Cette démarche repose sur la recherche d’anomalies décelables en raison des modifications de la structure des cellules qu’elles entraînent. La facilité et la fiabilité des diagnostics dépendent de l’expérience et de l’entraînement à la lecture microscopique et surtout du degré d’attention et d’acuité porté à la recherche et à l’interprétation de signes de modifications cellulaires significatifs parfois très difficiles à reconnaître. D’où l’intérêt d’utiliser un système d’aide à la décision.

La figure 1 présente les différents composants de ce projet. La station d’analyse de microscopie automatisée développée (vignette 2) effectue une caractérisation des cellules suivie d’une classification de type cellulaire pour pouvoir être intégrée dans une base de données d’images indexées. Différents utilisateurs interagissent avec ce système (vignettes 1, 2 et 3) suivant leur fonction. Le spécialiste crée une base d’apprentissage ou participe à son évolution (vignette 3). Les opérateurs préparent l’acquisition des cellules à analyser (vignette 1) à partir des différents prélèvements effectués. Le cyto-pathologiste effectue une expertise à partir des données visuelles extraites par le système et produit ainsi un diagnostic (vignette 4).

La segmentation d’image constitue une partie clé d’un tel système qui conditionne toutes les étapes ultérieures. La segmentation est un domaine réputée difficile en analyse d’images. En effet il n’existe pas de théories s’appliquant à différents types d’images, mais plutôt des méthodes variées que l’on choisit et que l’on développe pour résoudre des problèmes d’analyse sur un type d’image bien défini. Le choix de la méthode est généralement motivé par la représentation d’images que l’on choisit d’adopter. En imagerie

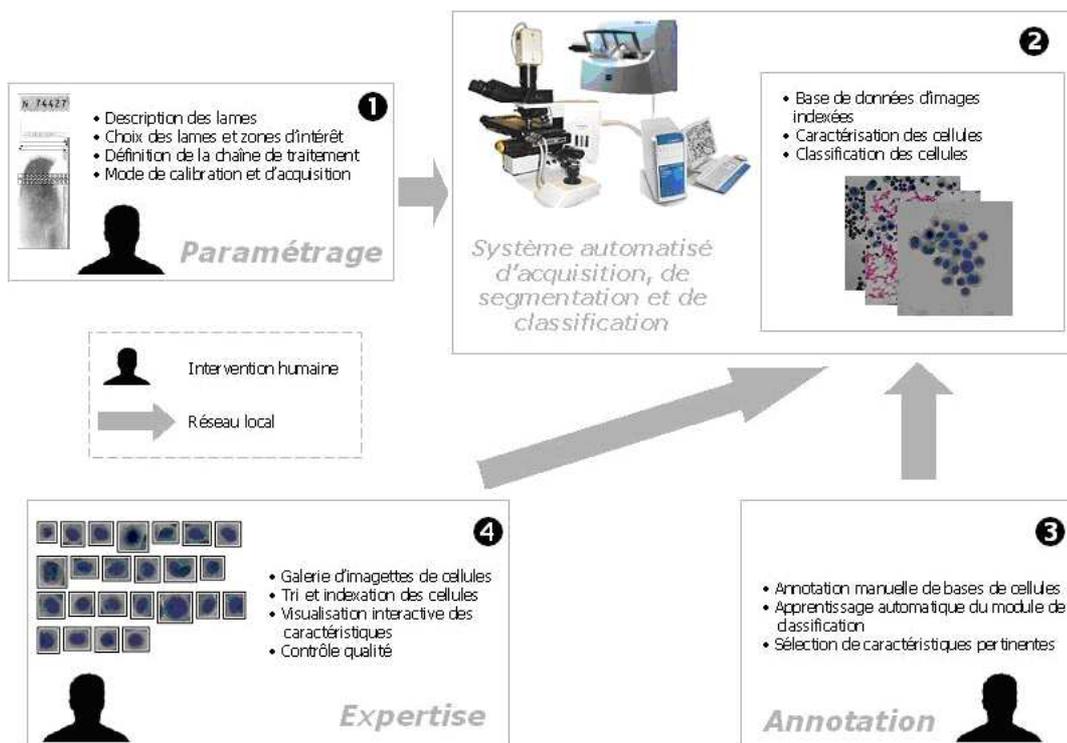


FIG. 1.1 – Projet d'une station d'analyse de microscopie automatisée pour la cytopathologie.

médicale microscopique, ce choix est d'autant plus difficile que l'on a à traiter différents types d'images selon les organes étudiés, la coloration adaptée, la variabilité des objets cellulaires et tissulaires observés.

L'étude présentée dans la première partie de ce manuscrit a pour objectif d'effectuer une segmentation automatique d'images microscopiques couleur qui sera illustrée sur des images de cytologie bronchique obtenues en entrée de ce système. La qualité de cette segmentation est primordiale puisque la qualité du diagnostic en dépend. La couleur constituant une source d'information importante dans le domaine de la microscopie biomédicale cellulaire, nous présenterons une méthode de segmentation d'images par classification pixellaire basée sur la couleur. L'influence du choix de l'espace de représentation couleur dans le processus de classification pixellaire sera présenté. Une nouvelle méthode d'évaluation de la qualité de la segmentation adaptée à la cytologie (en terme d'objets cellulaires) sera présentée. Nous proposerons deux approches de classification pixellaire non supervisée avec les algorithmes des k-moyennes et de Fisher, que nous nommerons « classification pixellaire en une étape » et « classification pixellaire en deux étapes » permettant de classer des objets délicats comme c'est le cas en cytologie bronchique. Une approche par classification pixellaire supervisée sera également réalisée avec les algorithmes de Bayes, Machines à Supports de Vecteurs, k plus proches voisins, Réseaux de Neurones Multi-Couches. L'utilisation de plusieurs classifications pixellaires entraînant des conflits de décisions, nous proposerons une méthode de combinaison prenant en compte le nombre de classifieurs fusionnés ainsi que l'information de voisinage. Enfin, nous terminerons cette première partie en intégrant ces différentes méthodes dans une approche

morphologique basée sur une Ligne de Partage des Eaux couleur afin d'obtenir une segmentation des différents objets plus précise.

L'autre partie de cette thèse sera consacrée à la segmentation d'images couleur, déconnectée de toute application. Nous ne considérerons plus l'image comme un ensemble de pixels comme cela pouvait être le cas dans la première partie, mais plutôt comme un ensemble de régions. Nous nous placerons dans le cas où nous ne disposons pas d'information *a priori* sur les zones d'intérêt de l'image ou sur les caractéristiques des objets d'intérêt. Dans ce contexte la segmentation d'images couleur peut être vue non plus comme une partition associée à une image mais plutôt comme une hiérarchie de partitions représentant l'image à différents niveaux.

Nous proposons alors dans la deuxième partie de cette thèse, différentes méthodes de création de hiérarchie de partitions. Dans un premier temps, nous définissons un nouveau critère connectif permettant d'obtenir les zones homogènes d'une image dont la finesse est réglable par un unique paramètre. L'utilisation de la couleur dans les opérations de morphologie mathématique entraînant des problèmes pour la définition d'un treillis complet, nous présentons une stratégie basée sur une décimation itérative d'un graphe associé à un élément structurant qui permet de pallier les défauts des approches morphologiques couleur classiques. Ceci permettant de redéfinir une méthode de création de hiérarchie de partitions basée sur une hiérarchie de Ligne de Partage des Eaux non paramétrique. Nous présentons ensuite pour la simplification et la segmentation d'image, une stratégie hiérarchique rapide sur graphe d'adjacence de régions. Pour finir, nous présentons une méthode permettant d'évaluer automatiquement le meilleur niveau d'une hiérarchie de partitions et pouvant être utilisée comme critère de terminaison pour la simplification d'une partition par fusion de régions par descente d'énergie.

Plan de la thèse

Cette thèse s'articule autour de deux grandes parties à savoir « la segmentation d'images couleur par classification pixellaire » et « la segmentation d'images couleur par hiérarchie de partitions ». La première (correspondant aux chapitres 2, 3, 4 et 5) se situe dans un cadre de segmentation d'images couleur pouvant être appliqué à la microscopie de cytologie bronchique. La deuxième (correspondant aux chapitres 6 et 7) est utilisée quant à elle dans un cadre plus général. Une conclusion où nous résumons les principaux résultats et présentons les extensions possibles de nos travaux sera présentée après celle-ci. Nous rappellerons en annexe de ce manuscrit, les différents éléments intervenant dans le processus de perception de la couleur chez l'être humain.

Nous commencerons ce manuscrit par le chapitre 2 en rappelant les notions de base des différents espaces de représentation des images couleur qui seront utilisés dans la suite de celui-ci.

Le chapitre 3 présente un état de l'art des différentes méthodes de segmentation d'images couleur. Nous insisterons davantage dans ce chapitre sur les méthodes de classification

pixellaire.

Le chapitre 4 traite un problème bien connu de celui des traiteurs d'images qui est celui de l'évaluation de la qualité de la segmentation. Nous y présentons les méthodes les plus couramment utilisées dans la littérature et proposerons une méthode d'évaluation adaptée au domaine de la cytologie.

Nous traiterons en détail dans le chapitre 5, deux approches de classifications pixellaires à savoir la classification pixellaire supervisée et non supervisée. Dans cette dernière approche, nous proposerons deux techniques permettant de classer des objets délicats. Nous présenterons une méthode de combinaison de classifications pixellaires afin d'augmenter la robustesse de notre système. Nous terminerons ce chapitre en intégrant ces méthodes dans une approche morphologique.

Le chapitre 6 présentera un état de l'art des méthodes morphologiques de segmentations hiérarchiques ainsi que différentes approches de fusion de régions permettant de réduire la sur-segmentation produite.

Nous détaillerons dans le chapitre 7 de nouvelles approches hiérarchiques. Nous proposerons un nouveau critère connectif permettant d'obtenir des zones homogènes de finesse variable. Nous proposerons une nouvelle approche de la morphologie mathématique couleur basée sur la décimation de l'arbre de recouvrement minimum du Graphe d'Adjacence de Régions pour un élément structurant donné. Nous étendrons ensuite cette approche à la définition d'une méthode de segmentation hiérarchique. Une méthode rapide de production d'une hiérarchie de partitions en combinant un lissage sur graphe d'adjacence de régions avec une décimation du graphe sera aussi présentée. Enfin, nous proposerons une méthode d'évaluation permettant de déterminer automatiquement le meilleur niveau d'une hiérarchie de partitions ou pouvant être utilisée comme critère de terminaison dans un processus de fusion de régions par descente d'énergie.

PREMIÈRE PARTIE

**SEGMENTATION D'IMAGES COULEUR
PAR CLASSIFICATION PIXELLAIRE**

LA REPRÉSENTATION DE LA COULEUR

Sommaire

2.1	Images microscopiques de cytologie bronchique	7
2.2	Les différents modèles de représentation de la couleur	9
2.3	Les espaces de représentation couleur	10
2.4	Synthèse des différents espaces couleurs	22
2.5	Conclusion	26

DANS ce chapitre, nous commençons par présenter la nature des images microscopiques de cytologie bronchique traitées dans la première partie de ce manuscrit ainsi que le protocole d'acquisition utilisé. Nous présentons ensuite un certain nombre de modèles de représentation de la couleur qui sont les fondements de tout espace couleur ainsi que différents espaces de représentation de la couleur. Nous y rappelons les définitions des principaux espaces que l'on peut trouver dans la littérature qu'ils soient utilisés dans un cadre de segmentation, d'indexation ou pour des applications spécifiques comme l'impression couleur ou encore la télévision. Nous terminons ce chapitre par quelques illustrations et notamment la visualisation d'une image après un changement d'espace couleur ou suite à une quantification en 16 couleurs effectuée par un algorithme classique de classification pixellaire.

2.1 Images microscopiques de cytologie bronchique

Les images couleurs que nous allons traiter dans la première partie de ce manuscrit sont des images microscopiques de cytologie bronchique telles qu'illustrées sur la figure 2.1.

Dans un cadre de segmentation d'images couleur, les traitements effectués dépendent fortement de la nature de ces dernières et notamment des couleurs présentes dans celles-ci. En effet, nous devons retrouver une certaine reproductibilité des couleurs présentes dans nos images et ceci quelque soit l'instant ou celles-ci ont été acquises. Pour ce faire, LEZORAY ET AL. [CAILLO05, LEZORA06] ont défini un mode opératoire strict et développé un procédé complet de calibration couleur pour des acquisitions d'images microscopiques. La station d'acquisition est composée d'un microscope OLYMPUS BX 50 avec une platine motorisée Märzhäuser et une caméra 3CCD JVC KY-F75 reliée à l'ordinateur par un port IEEE 1394.

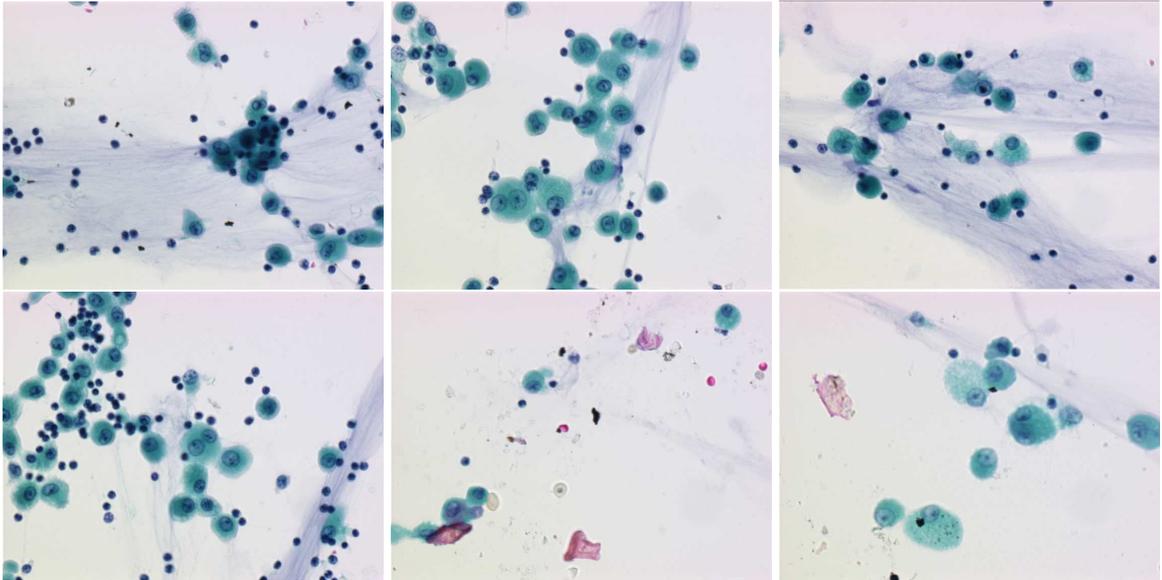


FIG. 2.1 – Images microscopiques de cytologie bronchique.

2.1.1 Paramètres du microscope

Avant d'acquérir une série d'images, nous devons veiller à ce que la température du système d'acquisition soit quasi-stable. Pour déterminer cette phase d'équilibre thermique, nous avons procédé à l'acquisition d'une image toutes les cinq minutes pendant trois heures. En mesurant le niveau de gris moyen dans l'image résultant de la différence entre deux acquisitions successives, nous pouvons tracer l'évolution des valeurs au cours du temps après que le système ait été alimenté. Ceci a permis d'indiquer que la stabilisation thermique du système est obtenue après 90 min de chauffe (toutes les expériences futures sont donc effectuées au moins 90 min après la mise sous tension du système). Le niveau d'éclairage du microscope a été fixé à une tension électrique constante de 9V correspondant à une température de couleur de 5500°K (illuminant D55 recommandé pour la microscopie). Le niveau d'ouverture du diaphragme nivelle la quantité de lumière passant par l'objectif. Pour déterminer le niveau d'ouverture optimum du diaphragme, une lame étalon possédant 10 patchs transmettant de 10% à 100% de la lumière incidente a été utilisée. Théoriquement les photodiodes ont une réponse linéaire en ce qui concerne l'intensité de la lumière incidente. Pour l'évaluation de la linéarité, nous avons mesuré la luminance par rapport à la transmission des filtres pour plusieurs ouvertures de diaphragme et utilisé une droite de régression linéaire. Les niveaux d'ouverture du diaphragme optimum ont été calculés comme étant respectivement de 0.25 pour un rapport optique 20x et de 0.5 pour un rapport optique 40x. Une fois tous ces paramètres du microscope fixés, nous devons procéder à un calibrage radiométrique des images. Le calibrage radiométrique doit permettre de s'assurer que chaque pixel possède une réponse photométrique identique quelque soient les sources de perturbations radiométriques subites. Le modèle de correction radiométrique défini est alors le suivant :

$$I_{exacte}^i = \frac{I_{acquise}^i - I_{obscurite}^i - I_{transmission}^i}{g_{objectif}^i} \quad (2.1)$$

où I_{exacte}^i correspond à la couleur exacte d'un pixel i si le système complet est parfait (sans source de perturbation), $I_{acquise}^i$ au pixel de l'image acquise devant être corrigé, $I_{obscurite}^i$ au bruit thermique, $I_{transmission}^i$ au bruit de transmission entre la caméra et le système d'acquisition.

A ce stade, nous pensons que l'espace de représentation couleur utilisé peut avoir une influence sur les résultats obtenus. C'est pourquoi, nous présentons ci-après les principaux espaces couleurs utilisés dans la suite de ce manuscrit afin de vérifier cette hypothèse supposée à priori.

2.2 Les différents modèles de représentation de la couleur

C'est au XIX siècle que T. YOUNG établit la théorie trichromatique de la lumière qui fut par la suite améliorée par H.V. HELMOLTZ. Nous savons alors que la rétine possède trois types de cônes photorécepteurs couleur qui répondent à la lumière incidente avec trois courbes (S, M et L) de réponse ayant chacune un pic d'absorption respectivement à une longueur d'onde de 440 nm, 545 nm et 570 nm. Il est alors possible de créer presque n'importe quelle couleur du spectre visible à partir des trois couleurs rouge, verte et bleue. Ce modèle nommé *modèle de tri-stimulus* est très répandu et notamment utilisé dans le codage de certains espaces de représentation couleur.

Un autre modèle portant le nom de *modèle des couleurs opposées* fut établi par E. HERING au XIX siècle et est basé sur le fait que toutes les couleurs peuvent être décrites comme contenant du rouge et du vert mais pas les deux en même temps. Ce modèle organise donc la couleur selon deux composantes chromatiques (correspondant respectivement à l'axe rouge-vert et l'axe bleu-jaune) et une composante achromatique (correspondant à l'axe blanc-noir représentant la luminosité).

Le modèle de Faugeras instauré par ce dernier [FAUGER79] est une combinaison du modèle de tri-stimulus et des couleurs opposées. Il est composé de trois parties dont la première consiste à transformer à l'aide des cônes photorécepteurs, la lumière incidente en trois signaux. La deuxième partie utilise un opérateur logarithmique de façon à reproduire la réponse spectrale des trois types de cônes S, M et L. Enfin, la dernière étape transforme comme le précédent modèle, le tri-stimulus en deux composantes chromatiques et une composante achromatique.

PRATT dans ces travaux [PRATT78] souligne que même si le modèle de tri-stimulus est très utilisé, il reste difficile de lier la perception humaine d'une couleur avec les composantes d'un espace couleur et propose de parler de teinte, de saturation et de luminance pour décrire une couleur.

Des modèles plus élaborés que ce que nous venons de citer ont été proposés en 1998 et en 2002 par la CIE. Ces modèles sont nommés *modèle d'apparence colorée* (CIECAM) et tentent de prendre en compte les différents mécanismes visuels intervenant dans la perception humaine de la couleur. Ces modèles rajoutent des notions d'interprétation de la

couleur et permettent d'exprimer la couleur d'un objet en décomposant l'environnement d'illumination et le stimulus couleur (Lightness, Chroma, Hue, Brightness, Colorfulness, Saturation). L'application d'un tel modèle implique qu'une image qui est regardée dans certaines conditions d'éclairage peut être ajustée pour sembler avoir les mêmes couleurs que si elle était regardée dans des conditions complètement différentes. Le lecteur intéressé par de plus amples informations pourra consulter [CIE98, MORONE02, CIE02].

2.3 Les espaces de représentation couleur

2.3.1 Les systèmes de primaires

Après avoir rappelé différents modèles de représentation de la couleur, nous allons maintenant montrer comment représenter les différentes teintes du spectre lumineux. Les premières études ont montré que l'on pouvait répondre à cela en effectuant une représentation fréquentielle ou en utilisant des espaces couleurs à plusieurs dimensions. Cette première approche fut abandonnée devant la simplicité d'utilisation des espaces couleur. La CIE a alors montré qu'il suffisait de trois variables indépendantes pour décrire presque toutes les couleurs du spectre visible et nous avons alors assisté à l'utilisation de systèmes de coordonnées en trois dimensions. Nous allons donc présenter dans la suite de ce chapitre différents espaces de représentation couleur.

2.3.1.1 L'espace RGB

L'espace RVB (RGB en anglais, nous utiliserons indifféremment les deux notations) est un système additif défini à partir des trois primaires monochromatiques de couleur rouge, verte et bleue présentées sur la figure 2.2. Il utilise le système de coordonnées cartésiennes et comme le montre la figure 2.3, la diagonale allant du blanc $(1, 1, 1)$ au noir $(0, 0, 0)$ (pour des valeurs de pixels comprises entre 0 et 1) est appelé *axe des gris* ou *axe achromatique*.

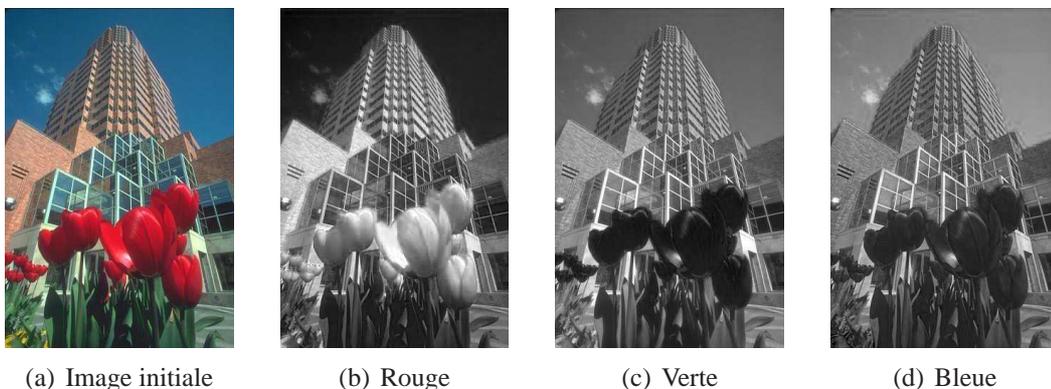
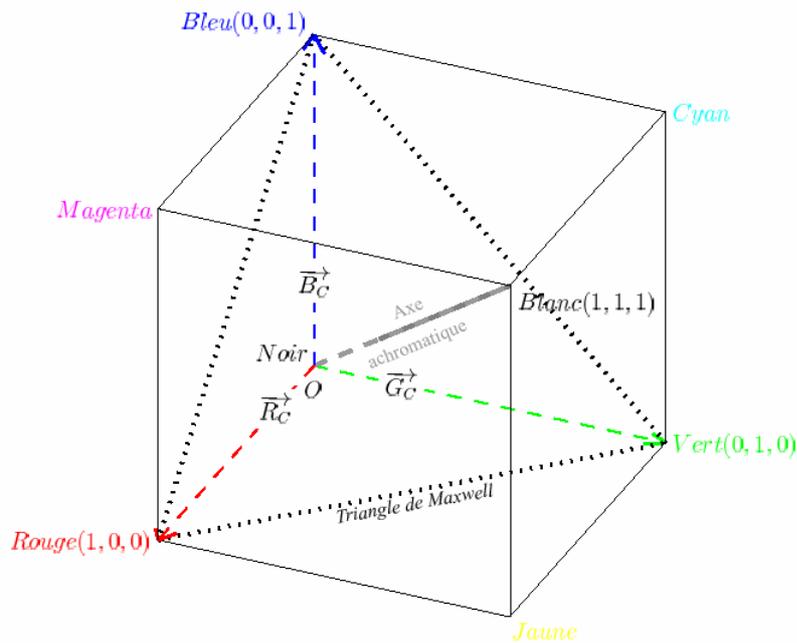


FIG. 2.2 – Décomposition d'une image RGB de la « Berkeley Segmentation Dataset and Benchmark » [BERKEL] selon les trois composantes R , G , et B .

FIG. 2.3 – La représentation spatiale du modèle RGB .

L'espace RGB est de loin l'espace le plus utilisé dans le domaine de l'imagerie couleur de part sa facilité d'utilisation mais aussi de part la dépendance aux matériels (carte d'acquisition, carte vidéo, moniteur, caméra, etc) puisque ces derniers n'utilisent que les triplets (R, G, B) pour leurs échanges d'information. Cependant, la définition de l'espace de représentation de la couleur n'étant pas unique puisqu'il dépend des primaires ainsi que du blanc de référence ; différents systèmes ont alors vu le jour. Comme le remarque LOZANO [LOZANO98], le système de représentation RGB introduit par la CIE en 1931 noté (R_C, G_C, B_C) reste celui de référence même s'il présente quelques inconvénients décrits ci-dessous :

- comme le souligne VANDENBROUCKE [VANDEN00], il existe un grand nombre de systèmes RGB . Mais nous pouvons néanmoins distinguer ceux dédiés à la télévision et répondant aux normes : *NTSC* (National Television Standards Committee) utilisant les primaires de la *FCC* (Federal Communications Commission), *PAL* (Phase Alternation by Line) fixée par l'*EBU* (European Broadcasting Union) ou *SECAM* (SEquentiel Couleur A Mémoire) ;
- les coordonnées et les composantes trichromatiques peuvent prendre des valeurs négatives comme l'illustre la figure 2.4 ;
- certaines couleurs ne sont pas reproductibles par addition des trois spectres ;
- les valeurs des composantes trichromatiques sont liées à la luminance impliquant que deux stimulus de couleur peuvent avoir la même chrominance tout en ayant des composantes trichromatiques R_C, G_C et B_C différentes.

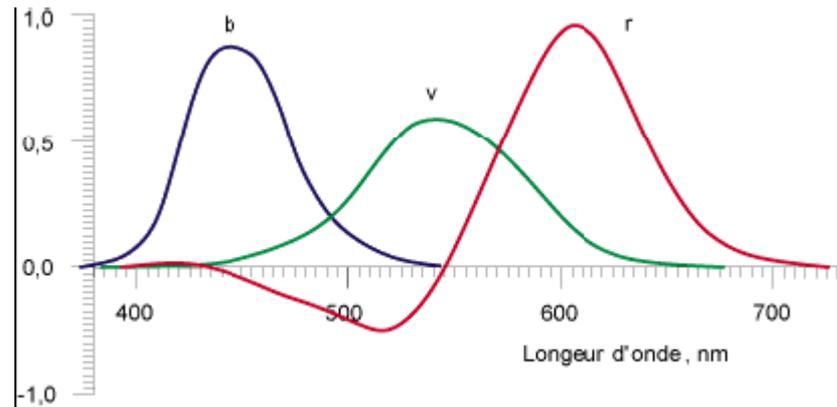


FIG. 2.4 – Variation du tri-stimulus RGB en fonction de la longueur d'onde.

Pour pallier cet inconvénient et obtenir des composantes ne tenant compte que de la chrominance, nous pouvons normaliser les valeurs des composantes trichromatiques par rapport à la luminance. Ces composantes ainsi normalisées sont alors définies comme suit :

$$\begin{bmatrix} r_c \\ g_c \\ b_c \end{bmatrix} = \begin{bmatrix} \frac{R_C}{R_C+G_C+B_C} \\ \frac{G_C}{R_C+G_C+B_C} \\ \frac{B_C}{R_C+G_C+B_C} \end{bmatrix} \quad (2.2)$$

2.3.1.2 L'espace XYZ

L'observation de la variation de tri-stimulus RGB en fonction de la longueur d'onde nous permet de constater la présence d'une valeur négative de la composante rouge pour certaines valeurs du spectre. La CIE décida alors de créer un espace dans lequel il n'existerait plus de valeurs négatives comme l'illustre la figure 2.5 et elle introduisit donc en 1931 un espace nommé XYZ ou CIE 1931 XYZ .

L'espace (X, Y, Z) devient alors le système de référence colorimétrique constitué de trois primaires X, Y et Z dites virtuelles obtenues par une simple transformation linéaire décrite dans l'équation suivante :

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = P \times \begin{bmatrix} R \\ G \\ B \end{bmatrix} = \begin{bmatrix} X_r & X_g & X_b \\ Y_r & Y_g & Y_b \\ Z_r & Z_g & Z_b \end{bmatrix} \times \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.3)$$

Les coefficients de la matrice de passage P sont déterminés par rapport à un blanc de référence qui conditionne les valeurs associées aux primaires X, Y et Z et par rapport aux primaires R, G, B (qui doivent appartenir à $[0, 1]$ au lieu de $[0, 255]$). Mais comme le fait remarquer TRÉMEAU [TRÉMEA93], nous pouvons constater dans la littérature quelques variations même minimales dans les valeurs de cette matrice. Néanmoins l'illuminant étant un élément à part entière de cette matrice, nous rappelons ci-dessous les six principaux illuminants normalisés de la CIE :

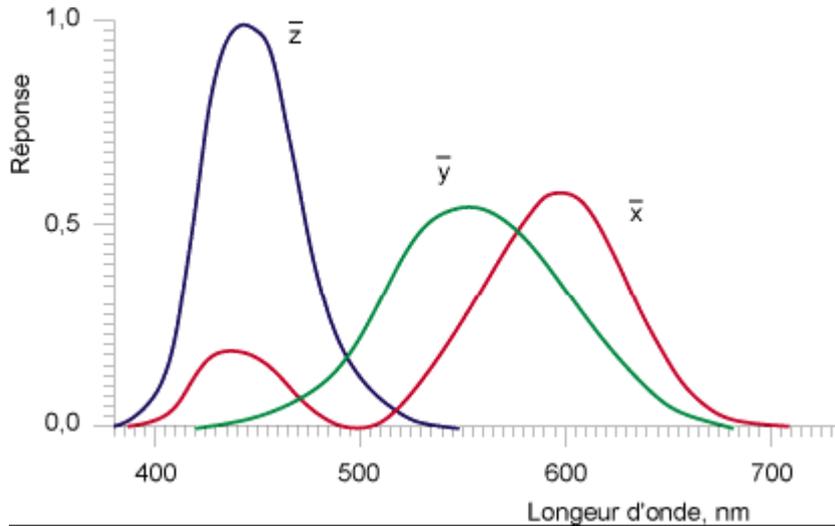


FIG. 2.5 – Variation du tri-stimulus XYZ en fonction de la longueur d'onde.

1. Illuminant A : il représente la lumière émise par un corps noir porté à la température de 2856 K. Ceci correspond à la source lumineuse produite par une lampe à filament de tungstène de 500W à une température de couleur de 2856 K ;
2. Illuminant B (retiré depuis 1986) : il représente la lumière directe du soleil à midi avec une température de couleur de 4870 K ;
3. illuminant C : il représente la lumière moyenne du jour avec une température couleur de 6770 K. Il est utilisé pour la norme $NTSC$ comme blanc de référence ;
4. Illuminant D : il représente les différentes lumières du jour. Mais afin de savoir de quelle lumière nous parlons, il a été adopté une notation faisant intervenir un indice lié à la température de couleur (par exemple, l'illuminant D_{65} correspond à la lumière du jour à une température couleur de 6500 K mais aussi à la moyenne des lumières durant une journée, ce qui en fait l'illuminant le plus utilisé. Il est aussi préconisé par l' EBU). D'autres illuminants D comme le D_{50} , D_{55} , D_{75} ont été développés en 1963 afin de remplacer les illuminants B et C ; ce dernier restant cependant encore très utilisé ;
5. Illuminant E : il représente une lumière d'énergie constante. Il ne correspond à aucune source lumineuse réelle et de ce fait ne reste que théorique. Les fonctions colorimétriques de la CIE sont obtenues en référence à cet illuminant ;
6. Illuminant F : il existe 12 illuminants F notés $F1$ à $F12$ représentant différentes lumières émises par les lampes fluorescentes. Pour exemple, l'illuminant $F2$ correspond à une lampe fluorescence standard.

En illustration, nous présentons ci-dessous la matrice de passage utilisant l'illuminant E . La transformation colorimétrique entre l'espace XYZ et l'espace RGB est alors donnée par :

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 2.7690 & 1.7518 & 1.1300 \\ 1.0000 & 4.5907 & 0.0601 \\ 0 & 0.0565 & 5.5943 \end{bmatrix} \times \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.4)$$

De même que pour le système RGB , la CIE a défini les coordonnées trichromatiques du système XYZ donnant un système normalisé (x, y, z) défini comme suit :

$$\begin{bmatrix} x \\ y \\ z \end{bmatrix} = \begin{bmatrix} \frac{X}{X+Y+Z} \\ \frac{Y}{X+Y+Z} \\ \frac{Z}{X+Y+Z} \end{bmatrix} \quad (2.5)$$

Comme $x + y + z = 1$, la couleur peut être représentée dans un plan (x, y) puisque z peut être déduit à partir des deux composantes chromatiques de la couleur x et y . On peut alors disposer du diagramme de chromaticité de la CIE qui décrit le plan défini par ces deux variables comme l'illustre la figure 2.6. Ce diagramme très utilisé permet de situer les couleurs les unes par rapport aux autres et de déterminer par simple construction géométrique, différents résultats comme la longueur d'onde, le blanc de référence, les couleurs complémentaires. Il permet également de visualiser les couleurs affichables par un écran par une mesure des chromacités des primaires (x, y) et du blanc de référence.

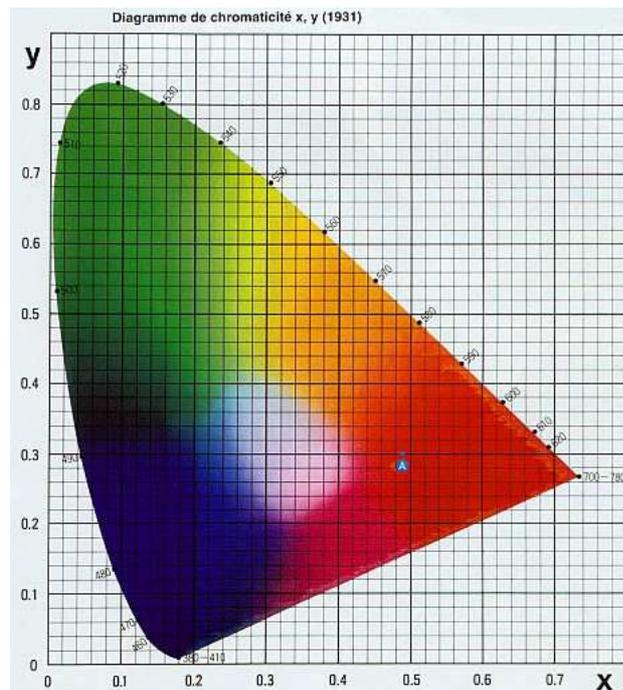


FIG. 2.6 – Le diagramme de chromaticité (x, y) de la CIE.

2.3.1.3 L'espace CMY

L'espace CMJ ou CMY est l'espace lié à l'impression des couleurs. Il résulte d'une synthèse soustractive et est représenté par un cube tout comme l'espace RGB . La différence avec ce dernier réside dans le fait que le cube CMY a le blanc pour origine et le cyan, le magenta, et le jaune comme axes. La transformation de l'espace RGB vers l'espace CMY est définie comme suit :

$$\begin{bmatrix} C \\ M \\ Y \end{bmatrix} = \begin{bmatrix} 1 - R \\ 1 - V \\ 1 - B \end{bmatrix} \quad (2.6)$$

2.3.2 Les espaces luminance-chrominance

2.3.2.1 l'espace AC_1C_2

L'espace AC_1C_2 introduit en 1976 utilise une fonction logarithmique afin de modéliser le fait que la réponse des cônes à un stimulus de couleur n'est pas proportionnelle à son intensité. En 1979, GARBAY [GARBY79] propose une simplification de cet espace en ne tenant pas compte des sensibilités spectrales des trois types de cônes. Mais l'utilisation de la fonction logarithmique reste très controversée et certains auteurs préfèrent supposer que la réponse des cônes de la rétine humaine est linéaire. La transformation de l'espace RGB vers l'espace AC_1C_2 et donc donnée par une composante achromatique A et deux composantes chromatiques C_1 et C_2 définies comme suit :

$$\begin{bmatrix} A \\ C_1 \\ C_2 \end{bmatrix} = \begin{bmatrix} \frac{\log(R)+\log(V)+\log(B)}{3} \\ \sqrt{\frac{3}{2}} (\log(R) - \log(V)) \\ \log(B) - \frac{1}{2} (\log(R) + \log(V)) \end{bmatrix} \quad (2.7)$$

Le calcul de la teinte et de la saturation peut alors être facilement effectué comme le montrent les équations ci-après :

$$\begin{aligned} S &= \sqrt{C_1^2 + C_2^2} \\ T &= a \cos\left(\frac{C_1}{S}\right) \end{aligned} \quad (2.8)$$

2.3.2.2 L'espace YCh_1Ch_2

L'espace YCh_1Ch_2 fut introduit en 1995 par CARRON [CARRON95, LAMBER99]. L'équation de luminance reste inchangée par rapport aux autres systèmes de luminance-chrominance mais les composantes Ch_1 et Ch_2 correspondent respectivement à une opposition cyan-rouge et vert-bleu. La transformation de l'espace RGB en l'espace YCh_1Ch_2 est donnée par :

$$\begin{bmatrix} Y \\ Ch_1 \\ Ch_2 \end{bmatrix} = \begin{bmatrix} 0.299 \times R + 0.587 \times G + 0.114 \times B \\ R - \frac{G+B}{2} \\ \frac{\sqrt{3}}{2} \times (B - G) \end{bmatrix} \quad (2.9)$$

Pour pouvoir afficher une image couleur, le récepteur de télévision décode le signal reçu sous forme de trois signaux primaires. Ces signaux dépendent des primaires et du blanc de référence utilisés qui dépendent eux aussi des normes imposées par les standards de chaque pays (*NTSC*, *PAL*, *SECAM* que nous avons explicités auparavant). A partir de ces signaux primaires, le récepteur effectue la synthèse additive de l'image couleur

[GALICH89]. Les espaces dédiés à la télévision que nous détaillerons ci-après ont été développés afin de pouvoir transmettre des informations colorées à des téléviseurs couleurs tout en gardant la possibilité d'afficher une image en niveau de gris sur des téléviseurs noir et blanc. Pour satisfaire ce principe, ces signaux séparent l'information de luminance et de chrominance que nous retrouvons dans les équations ci-dessous.

2.3.2.3 L'espace YUV

Le modèle YUV est un modèle de représentation de la couleur dédié à la vidéo analogique et utilisé dans les standards vidéo *PAL* et *SECAM*. Il utilise l'illuminant D_{65} comme blanc de référence. L'espace YUV présent dans les travaux de ULTRÉ, LIANG, CLARAMONT [ULTRÉ96, LIANG87, CLARAM84] et dont la transformation est issue de l'espace RGB est définie comme suit :

$$\begin{bmatrix} Y \\ U \\ V \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.114 \\ -0.147 & -0.289 & -0.436 \\ 0.615 & -0.515 & -0.100 \end{bmatrix} \times \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.10)$$

où Y représente la luminance, U et V la chrominance.

2.3.2.4 L'espace YIQ

Le modèle YIQ diffère peu du modèle YUV et tout comme le précédent, est utilisé dans les travaux de ULTRÉ, LIANG, CLARAMONT [ULTRÉ96, LIANG87, CLARAM84] ainsi que dans le standard vidéo *NTSC*. La transformation de l'espace RGB en l'espace YIQ est donnée par les relations suivantes :

$$\begin{bmatrix} Y \\ I \\ Q \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.114 \\ 0.596 & -0.274 & -0.322 \\ 0.212 & -0.523 & -0.311 \end{bmatrix} \times \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.11)$$

où le paramètre Y représente la luminance, I l'interpolation et Q la quadrature. I et Q sont aussi les composantes chromatiques représentant respectivement les oppositions cyan-orange et magenta-bleu.

2.3.2.5 L'espace YC_bC_r

L'espace YC_bC_r est le standard international dédié au codage digital des images de la télévision numérique. Il fait actuellement partie du nouveau standard de compression JPEG2000. Cet espace a la particularité par rapport aux autres espaces dédiés à la télévision de ne pas imposer de règle sur le blanc de référence à utiliser. La transformation de l'espace RGB en l'espace YC_bC_r est donnée par :

$$\begin{bmatrix} Y \\ C_b \\ C_r \end{bmatrix} = \begin{bmatrix} 0.2989 & 0.5866 & 0.1145 \\ -0.1688 & -0.3312 & 0.5 \\ 0.5 & -0.4184 & -0.0816 \end{bmatrix} \times \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.12)$$

Les espaces perceptuellement uniformes que nous pouvons classer dans les espaces luminance-chrominance nous permettent d'obtenir une harmonisation perceptuelle des différences entre les couleurs. Nous ne pouvons parler d'uniformité de perception dans un espace de représentation de la couleur que si les deux conditions suivantes sont remplies :

1. La distance euclidienne $d(c_1, c_2)$ entre deux couleurs c_1 et c_2 est correcte si et seulement si la valeur issue de cette distance se rapproche de la différence perçue par l'oeil humain ;
2. La distance euclidienne $d(c_i, c_1) = n \times d(c_i, c_2)$ est correcte si est seulement si l'oeil humain perçoit la couleur c_1 n fois plus éloignée de la couleur c_i que la couleur c_2 .

2.3.2.6 L'espace $L^*u^*v^*$

En 1960, la CIE recommande la transformation du plan de chromaticité afin de le rendre plus homogène dans la perception des couleurs. Elle propose ainsi un nouvel espace tri-dimensionnel nommé *CIE 1960 UVW* intégrant l'information de luminance. Ce dernier fut légèrement amélioré suite à une proposition d'EASTWOOD [EASTWO73] pour donner naissance en 1976 au système $L^*u^*v^*$ aussi appelé *CIE 1976 Luv*. Le passage du système *XYZ* à ce système s'effectue par les équations suivantes.

$$\begin{aligned}
 L^* &= 116 \times \left(\frac{Y}{Y_0}\right)^{\frac{1}{3}} - 16 & \text{si } \frac{Y}{Y_0} > 0,008856 \\
 L^* &= 903,3 \frac{Y}{Y_0} & \text{sinon} \\
 u^* &= 13 \times L^*(u' - u'_0) & \text{avec } u' = \frac{4X}{X+15Y+3Z} \text{ et } u'_0 = \frac{4X_0}{X_0+15Y_0} \\
 v^* &= 13L^*(v' - v'_0) & \text{avec } v' = \frac{9X}{X+15Y+3Z} \text{ et } v'_0 = \frac{9X_0}{X_0+15Y_0}
 \end{aligned} \tag{2.13}$$

où L représente la luminance, X_0, Y_0, Z_0 désignent les coordonnées *XYZ* de l'illuminant c'est-à-dire du blanc de référence, u^* et v^* donnent la chrominance de la couleur et donc respectivement l'opposition de couleur vert-rouge et l'opposition de couleur bleu-jaune.

2.3.2.7 L'espace $L^*a^*b^*$

La même année, la CIE a proposé un autre système perceptuellement uniforme appelé $L^*a^*b^*$ ou *CIE 1976 Lab*. Ce système est une approximation de l'espace d'Adams-Nickerson dans lequel l'amplitude perceptuelle de la couleur est définie en termes d'échelles de couleurs opposées couvrant l'intégralité du spectre visible par l'oeil humain. La représentation spatiale de cet espace tout comme celle de l'espace $L^*u^*v^*$ est donnée par une sphère comme l'illustre la figure 2.7. Le passage du modèle *XYZ* au modèle $L^*a^*b^*$ s'obtient à partir des relations non-linéaires données ci-dessous :

$$\begin{aligned}
 L^* &= 116 \times \left(\frac{Y}{Y_0}\right)^{\frac{1}{3}} - 16 && \text{si } \frac{Y}{Y_0} > 0,008856 \\
 L^* &= 903,3 \frac{Y}{Y_0} && \text{sinon} \\
 a^* &= 500 \left(f\left(\frac{X}{X_0}\right) - f\left(\frac{Y}{Y_0}\right)\right) \\
 b^* &= 300 \left(f\left(\frac{Y}{Y_0}\right) - f\left(\frac{Z}{Z_0}\right)\right)
 \end{aligned}
 \tag{2.14}$$

avec $f(x) = x^{\frac{1}{3}}$ si $x > 0,008856$ et $f(x) = 7,787x + \frac{16}{116}$ sinon

où L^* mesure la luminance et par conséquent l'opposition noir-blanc par une valeur comprise entre 0 (noir) et 100 (blanc). a^* mesure l'opposition vert-rouge par une valeur comprise entre -100 et $+100$ (a^* est positif si la couleur contient du rouge, négatif si la couleur contient du vert et nulle si aucun des deux). b^* mesure l'opposition bleu-jaune par une valeur comprise entre -100 et $+100$ (b^* est positif si la couleur contient du jaune, négatif si la couleur contient du bleu et nulle si aucun des deux). X_0, Y_0, Z_0 désignent comme dans l'espace $L^*a^*b^*$ les coordonnées XYZ de l'illuminant.

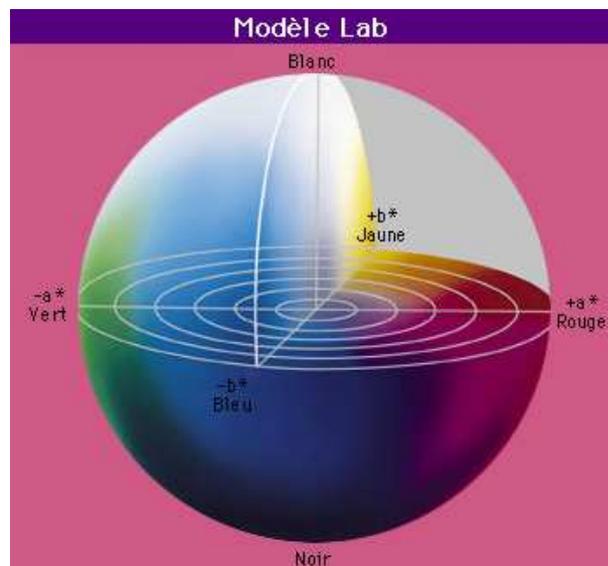


FIG. 2.7 – La représentation spatiale du modèle $L^*a^*b^*$.

Notons qu'il est possible de calculer une différence entre deux couleurs dans les espaces tri-dimensionnels. Ceci revient généralement à exprimer une distance euclidienne entre deux points calculée dans l'espace de représentation. L'espace $L^*a^*b^*$ a été proposé par la CIE dans le but de pouvoir évaluer des différences colorimétriques appliquées au monde industriel. Nous donnons ci-dessous les équations proposées en 1976 et permettant de définir les différences colorimétriques entre deux stimulus de couleurs des espaces $L^*a^*b^*$ et $L^*u^*v^*$:

$$\begin{aligned}\Delta E_{a^*b^*} &= \sqrt{(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2} \\ \Delta E_{u^*v^*} &= \sqrt{(\Delta L^*)^2 + (\Delta u^*)^2 + (\Delta v^*)^2}\end{aligned}\quad (2.15)$$

En 1994, la CIE propose une nouvelle formule d'évaluation de différences colorimétriques entre deux stimulus de couleurs. La précédente formule ne prenait pas en compte le fait que l'oeil humain est plus sensible à l'information de luminance qu'à celle de chrominance. Ceci est corrigé dans la nouvelle formulation par l'ajout de facteurs paramétriques (k_L, S_L, k_C) et fonctions de pondérations (S_C, k_H, S_H).

$$\Delta E_{ab}^* = \sqrt{\left(\frac{\Delta L^*}{k_L S_L}\right)^2 + \left(\frac{\Delta C_{ab}^*}{k_C S_C}\right)^2 + \left(\frac{\Delta H_{ab}^*}{k_H S_H}\right)^2}\quad (2.16)$$

Notons que l'utilisation de ces formules est assez stricte dans le sens où elles ont été définies pour des petites distances entre couleur et qu'elles ne présentent aucune garantie pour des distances importantes. De plus ces formules ne sont valables que pour des conditions de référence particulières. Le lecteur pourra obtenir de plus amples détails à ce sujet dans les travaux de CHARRIER [CHARRI98].

2.3.3 Les systèmes perceptuels

L'être humain ne perçoit pas la couleur comme une combinaison de composantes trichromatiques liées à des primaires mais plutôt comme des entités liées à la teinte, la saturation et la luminance. Il existe dans la littérature un grand nombre de systèmes perceptuels utilisant ces entités mais ils traitent dans la plupart des cas des mêmes grandeurs uniquement différenciées par leur calcul. C'est pourquoi, nous ne présenterons ici que trois espaces que nous avons pu relever comme les plus utilisés et que nous pouvons classer en deux catégories à savoir :

1. Les systèmes de coordonnées polaires ou cylindriques (transformation en coordonnées polaires des composantes de systèmes de luminance-chrominance) ;
2. Les systèmes humains de perception de la couleur (en utilisant directement les entités liées à la teinte, la saturation et la luminance).

2.3.3.1 L'espace $L^*C^*H^*$

L'espace L^*C^*H défini en 1995, que l'on retrouve dans les travaux de CELENK [CELENK95] et TRÉMEAU ET AL. [TRÉMEA95] est obtenu en transformant l'espace $L^*a^*b^*$ ou $L^*u^*v^*$ en coordonnées semi-polaires. Les composantes C^* et H^* représentent respectivement le chroma et la teinte. La luminance reste inchangée par rapport à celle décrite dans les espaces $L^*a^*b^*$ et $L^*u^*v^*$ et les deux autres composantes sont obtenues grâce aux équations suivantes :

$$\begin{aligned}
 C_{uv}^* &= \sqrt{u^{*2} + v^{*2}} \\
 C_{ab}^* &= \sqrt{a^{*2} + b^{*2}} \\
 H_{uv}^* &= \arctan\left(\frac{v^*}{u^*}\right) \\
 H_{ab}^* &= \arctan\left(\frac{a^*}{b^*}\right)
 \end{aligned}
 \tag{2.17}$$

Mais notons que la formule de la teinte définie ci-dessus ne permet pas de par la définition de arctan d'obtenir des angles supérieurs à une variation de -90 degrés à $+90$ degrés. Afin de corriger cet inconvénient et obtenir une teinte variant de 0 à 360 degrés, il est nécessaire d'appliquer les corrections suivantes (pour H_{uv}^* ou H_{ab}^*) :

$$\begin{aligned}
 H^* &= H_{uv}^* && \text{si } u^* > 0 \quad \text{et } v^* > 0 \\
 H^* &= H_{uv}^* + 180 && \text{si } u^* < 0 \quad \text{et } v^* > 0 \\
 H^* &= H_{uv}^* + 180 && \text{si } u^* < 0 \quad \text{et } v^* < 0 \\
 H^* &= H_{uv}^* + 360 && \text{si } u^* > 0 \quad \text{et } v^* < 0
 \end{aligned}
 \tag{2.18}$$

2.3.3.2 L'espace *HSL*

L'espace *HSL* est basé sur les trois grandeurs que nous venons d'introduire :

1. La teinte qui se trouve être la longueur d'onde prédominante ;
2. La saturation correspondant au degré de mélange de la longueur d'onde prédominante avec le blanc et donc au niveau de coloration d'une surface indépendamment de sa luminance ;
3. La luminance qui est l'intensité de la couleur.

La figure 2.8 donne la représentation spatiale du modèle *HSL* et la transformation colorimétrique entre l'espace *HSL* et l'espace *RGB* est donnée par :



FIG. 2.8 – La représentation spatio-colorimétrique du modèle *HSL*.

$$\begin{aligned}
H &= a \times \cos \left(\frac{(R-V)+(R-B)}{2\sqrt{(R-V)^2+(R-B)(V-B)}} \right) \quad \text{et si } V < B : H = 2\pi - H \\
S &= 1 - \frac{3 \times \min(R,V,B)}{L} \\
L &= R + V + B
\end{aligned} \tag{2.19}$$

La non-linéarité des équations permettant de calculer H et S entraînent des discontinuités dans les valeurs et de ce fait, deux couleurs perceptuellement proches peuvent avoir des valeurs de teinte et de saturation très différentes. Ceci est dû aux singularités de la teinte pour les points achromatiques ($R = V = B$) et de saturation pour le noir ($R = V = B = 0$).

2.3.3.3 L'espace $IHSL$

L'espace $IHLS$ défini en 2002 par HANBURY ET SERRA [HANBUR02] a été proposé comme une amélioration de l'espace HLS . L'amélioration consiste à passer de la version cylindrique de l'espace HLS à la version conique, ce qui revient à remplacer la saturation HLS par la semi-norme $max-min$. Notons que la luminance utilisée dans cet espace correspond à celle recommandée par le standard de la télévision de haute définition. L'espace $IHLS$ dont la transformation est issue de l'espace HSL est défini comme suit :

$$\begin{aligned}
H &= \begin{cases} \frac{g-b}{(\max(r,g,b)-\min(r,g,b))} & \text{si } r = \max(r, g, b) \\ \frac{b-r}{(\max(r,g,b)-\min(r,g,b))} + 2 & \text{si } g = \max(r, g, b) \\ \frac{r-g}{(\max(r,g,b)-\min(r,g,b))} + 4 & \text{si } b = \max(r, g, b) \end{cases} \\
L &= 0.213r + 0.715g + 0.072b \\
S &= \max(r, g, b) - \min(r, g, b)
\end{aligned} \tag{2.20}$$

2.3.4 Les système d'axes indépendants

Le principal inconvénient du système RGB est que ses trois composantes sont fortement corrélées. Chaque composante possède une information de luminance. Des auteurs ont donc cherché à développer des systèmes de représentation où chacune des composantes seraient décorréelées et pourraient être traitées indépendamment. Une des solutions a donc consisté à utiliser l'Analyse en Composantes Principales (ACP) c'est-à-dire appliquer la transformation de KARHUNEN-LOÉVE [SAVOJI85].

2.3.4.1 L'espace $I_1I_2I_3$

En 1980, OHTA ET AL. [OHTA80] ont introduit un nouvel espace nommé $I_1I_2I_3$ dans le but de produire une segmentation aussi satisfaisante que celle produite par la transformation de KARHUNEN-LOÉVE [SAVOJI85]. A chaque étape de la segmentation, de

nouvelles caractéristiques couleurs sont calculées par la transformation de KARHUNEN-LOÉVE des valeurs RGB . Les trois caractéristiques les plus significatives ont été retenues pour représenter les trois axes de l'espace $I_1I_2I_3$. Le passage du système RGB à ce système s'effectue par les équations suivantes.

$$\begin{bmatrix} I_1 \\ I_2 \\ I_3 \end{bmatrix} = \begin{bmatrix} 1/3 & 1/3 & 1/3 \\ 1/2 & 0 & -1/2 \\ -1/4 & 1/2 & -1/4 \end{bmatrix} \times \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.21)$$

où I_1 représente la luminance, I_2 et I_3 correspondent respectivement une opposition bleu-rouge et magenta-vert.

2.4 Synthèse des différents espaces couleurs

La littérature abondant de travaux sur les espaces de représentation de la couleur, de nombreux auteurs ont tenté de classer les espaces en différents groupes. La répartition de VANDENBROUCKE [VANDEN00] ou de BUSIN ET AL. [BUSIN04A, BUSIN04B] nous semble la plus appropriée à la présentation que nous avons fait de ces espaces. Nous illustrons donc sur la figure 2.9, un premier regroupement en dix sous familles (représentées par des blocs en pointillés), des différents espaces de représentation couleur présentés dans ce chapitre. Un deuxième regroupement de ces sous familles est réalisé de sorte à obtenir quatre grandes familles (représentées par des blocs à bordure noire) correspondant aux systèmes primaires, systèmes de luminance-chrominance, systèmes perceptuels et systèmes d'axes indépendants.

Une illustration de plusieurs espaces de représentation couleur est présentée sur les figures 2.10, 2.11 et 2.12. Il ne s'agit pas ici de comparer ou de définir le meilleur espace couleur existant mais plutôt d'illustrer sur une image plusieurs espaces que nous avons présentés dans ce chapitre. Nous utiliserons pour cette étude ainsi que pour le reste des travaux présentés dans ce manuscrit une sélection de neuf espaces couleurs qui sont : RGB , XYZ , $L^*u^*v^*$, $L^*a^*b^*$, $L^*c^*h^*$, HSL , YIQ , $YCbCr$, $I_1I_2I_3$ et qui correspondent majoritairement aux espaces utilisés dans la littérature pour la segmentation d'images couleur. Les figures 2.10 et 2.11 illustrent respectivement la représentation d'une image couleur de building extraite de la « Berkeley Segmentation Dataset and Benchmark (BSD3) » [BERKEL] dans différents espaces couleur et l'image couleur après transformation dans l'espace étudié. La figure 2.12 représente quant à elle l'image re-colorisée après une quantification en 16 couleurs effectuée par l'algorithme des k-moyennes dans les différents espaces étudiés.

Aux vues des figures 2.10, 2.11 et 2.12, nous pouvons apporter quelques constatations. La représentation de l'image couleur est très différente selon l'espace de représentation couleur que l'on utilise (figure 2.10). Pour l'exemple sur lequel nous travaillons, c'est-à-dire, une image couleur de building, nous assistons à des représentations compactes pour les espaces couleurs RGB , XYZ , YIQ , $I_1I_2I_3$ et plus allongées pour les espaces $L^*c^*h^*$, HSL . La transformation de cette même image dans différents espaces de représentation couleur laisse paraître des disparités. Les espaces RGB , XYZ et HSL semblent bien faire ressortir les différents objets de l'image. Ceci peut se vérifier sur la figure 2.12 représentant une re-colorisation de l'image suite à une opération simple de quantification en 16 couleurs

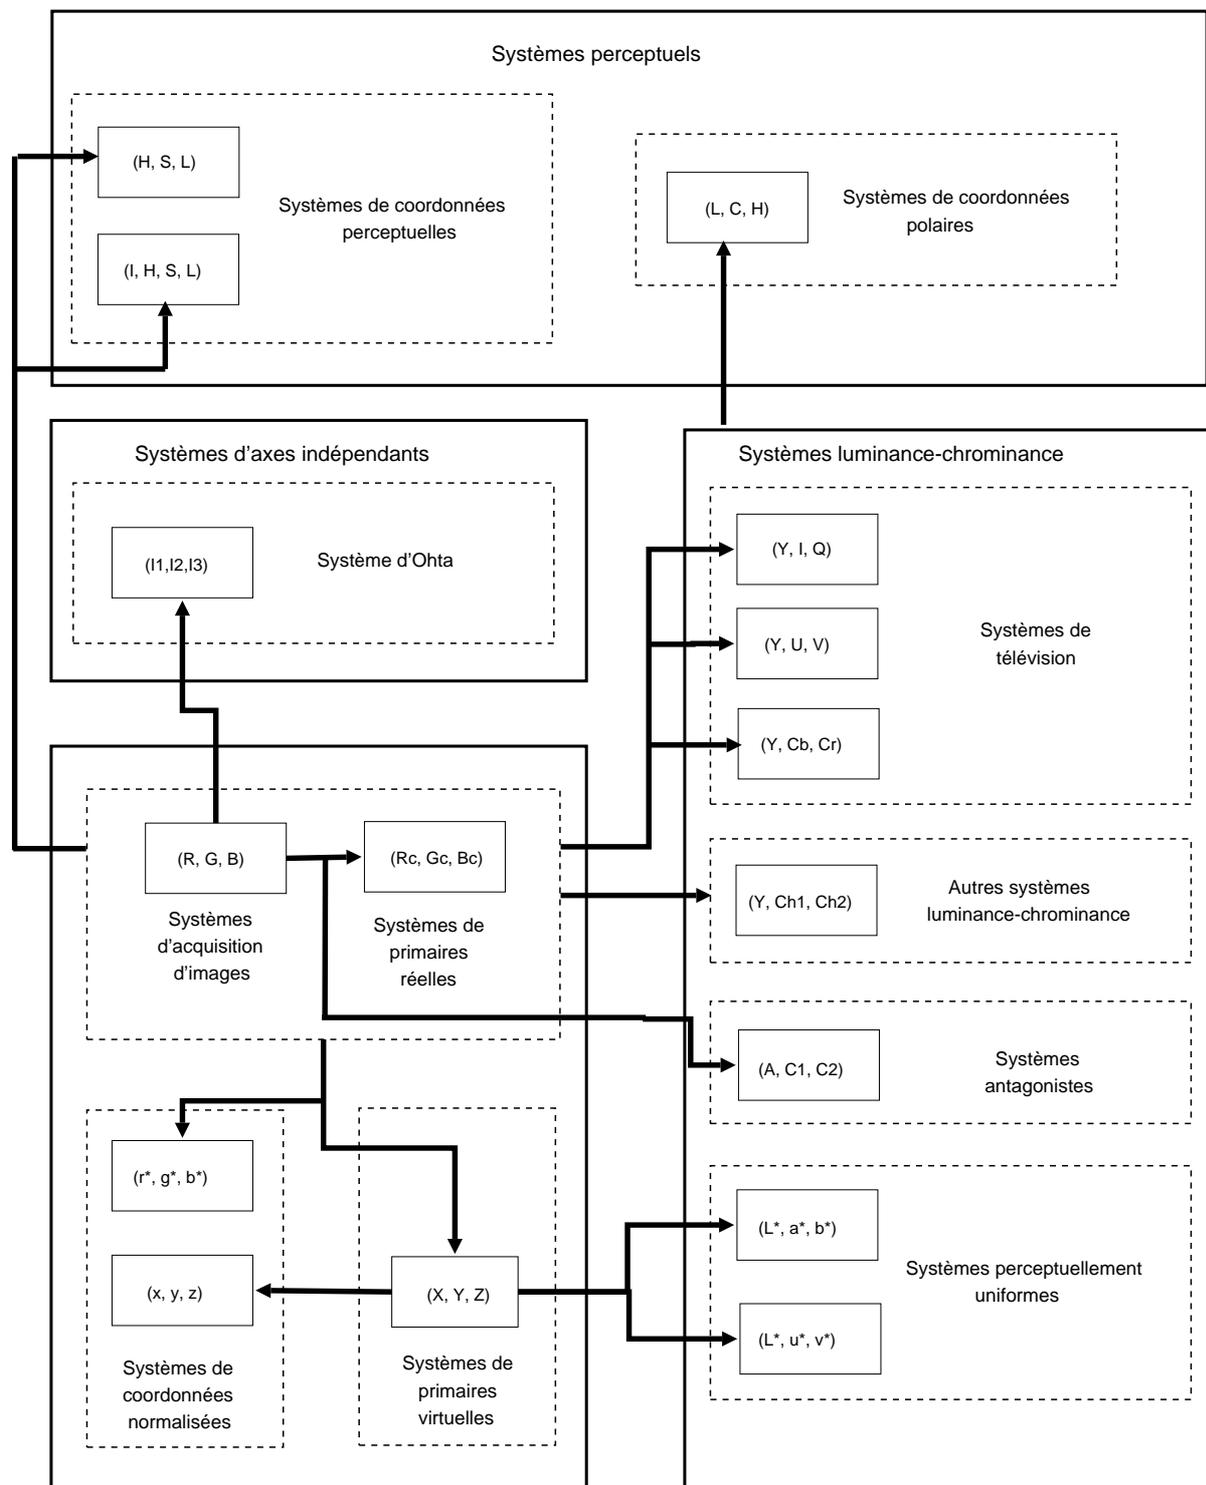


FIG. 2.9 – Schéma des différentes familles d'espaces de représentation couleur, inspiré de celui de VANDENBROUCKE [VANDEN00]



(a) Image extraite de la « BSDB » [BERKEL]

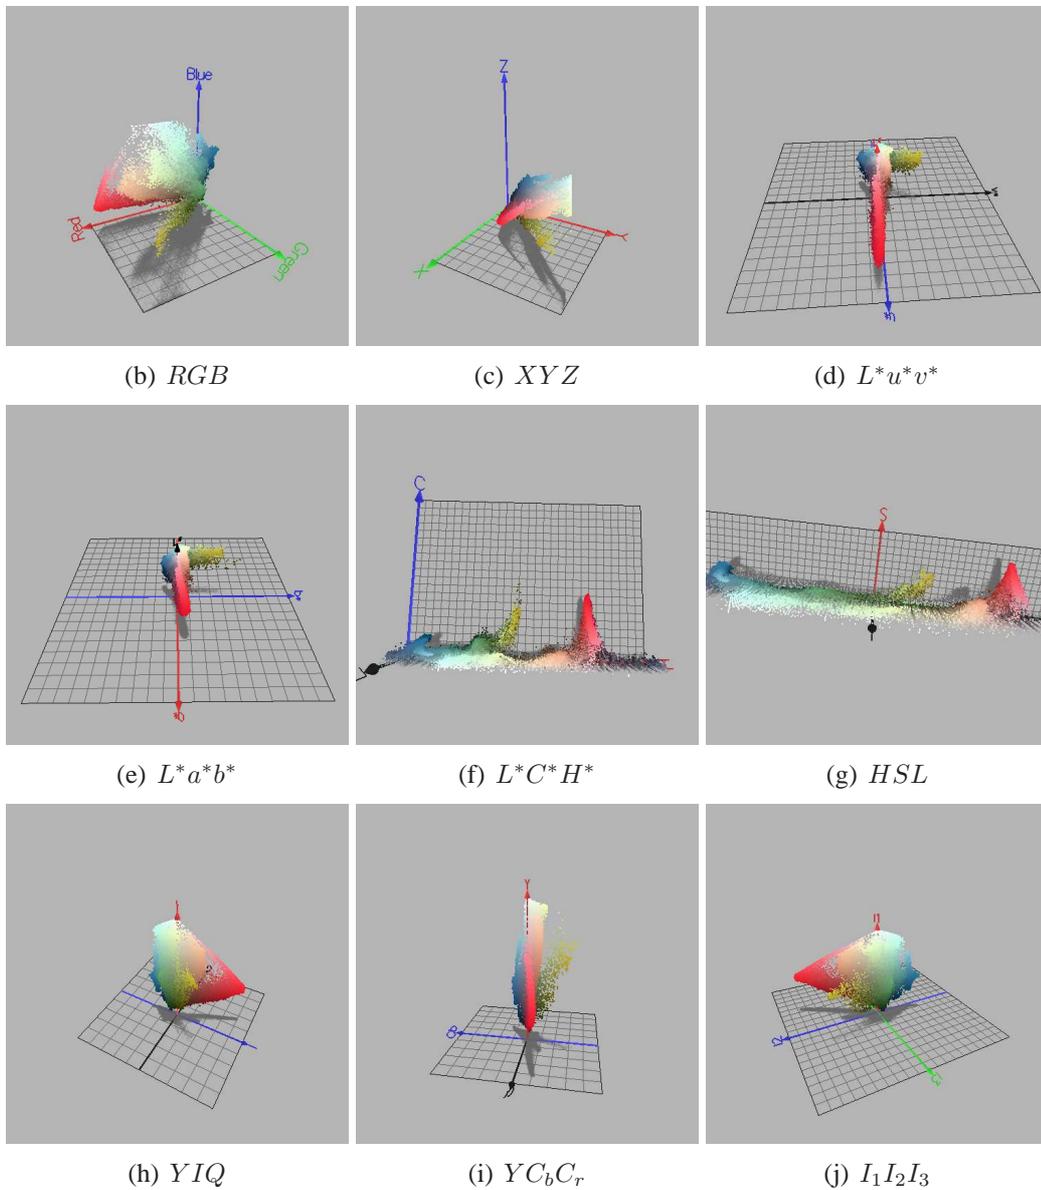


FIG. 2.10 – Représentation de l'image couleur dans différents espaces couleur effectuée à l'aide du logiciel « ColorSpace » (<http://www.couleur.org/>).

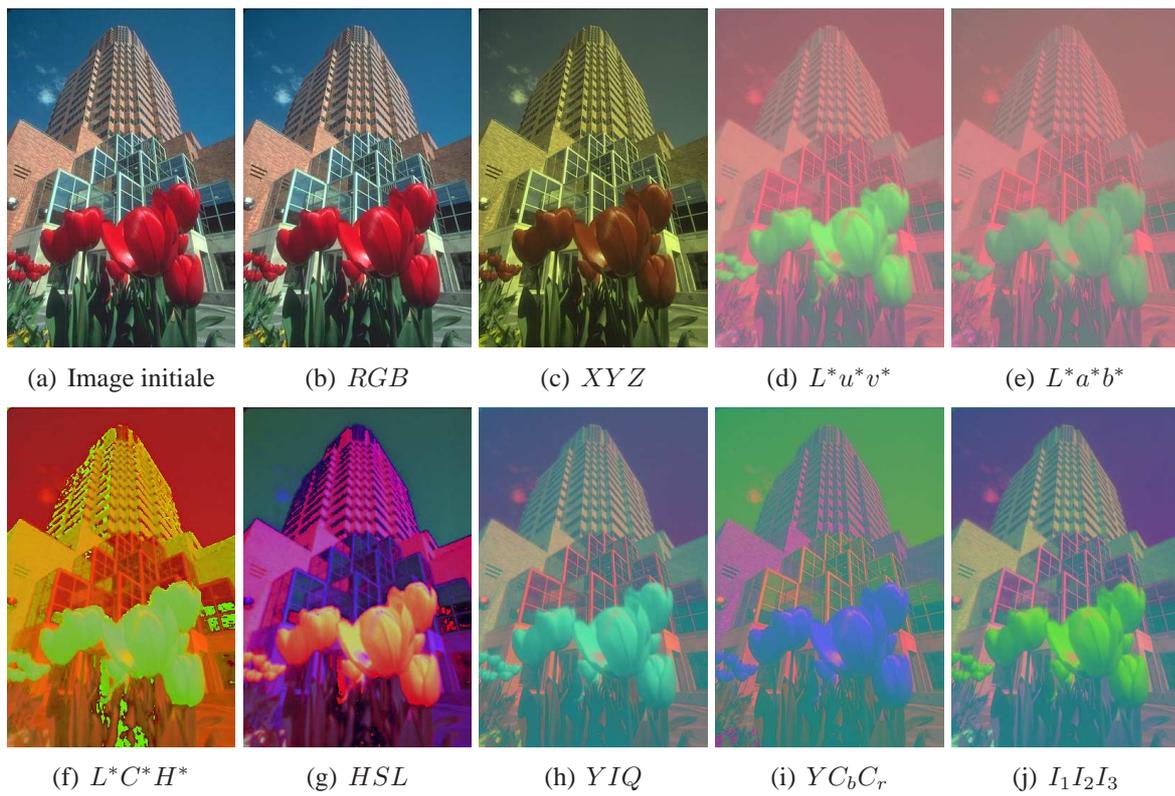


FIG. 2.11 – Image dans différents espaces de représentation couleur.

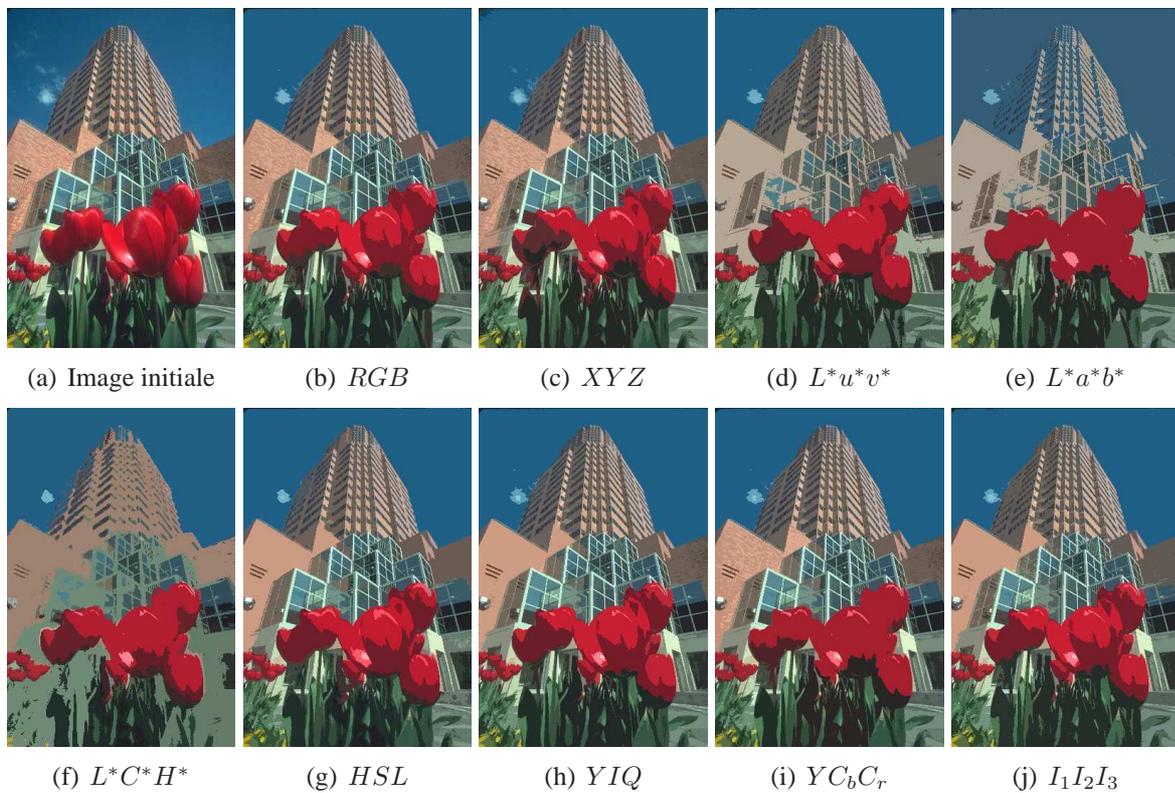


FIG. 2.12 – Image re-colorisée après une quantification en 16 couleurs de l'image couleur par l'algorithme des k-moyennes et dans différents espaces de représentation couleur.

par l'algorithme des k-moyennes. Cependant, nous pouvons remarquer sur les espaces $L^*u^*v^*$, $L^*a^*b^*$ que la différence de couleur est proche entre le building, les vitres et le ciel, ce qui entraîne une mauvaise classification des objets puisque l'on retrouve des vitres et des parties du building classées comme du ciel. Cette remarque est accentuée pour l'espace $L^*c^*h^*$ où les différents objets de l'image sont représentés en jaune, orange et rouge. Leurs couleurs étant relativement proches, il n'est pas aisé de les différencier précisément, ce qui a pour conséquence de fournir de mauvais résultats sur la quantification en 16 couleurs. Les résultats que nous venons de présenter sur une image illustre donc l'importance du choix de l'espace de représentation couleur.

2.5 Conclusion

Ce chapitre consacré à la représentation de la couleur a permis de rappeler la plupart des espaces de représentation couleur que nous pouvons rencontrer dans la littérature. Des illustrations sur une image obtenue dans différents espaces couleurs par simple transformation ou après une quantification en 16 couleurs par l'algorithme des k-moyennes ont été présentées. Pour l'image présentée, il n'est pas évident de conclure sur la réelle supériorité d'un espace couleur par rapport à un autre. Ce qui paraît évident puisque les différents espaces couleurs ont été conçus au fur et à mesure de différents besoins et certains sont liés soit à des méthodes et/ou concepts ou bien des applications spécifiques. Nous nous attacherons donc à tester tous ces espaces dans le chapitre consacré à la segmentation par classification pixellaire afin de déterminer celui qui sera considéré comme le meilleur pour une application donnée.

SEGMENTATION D'IMAGES COULEUR

Sommaire

3.1 La classification pixellaire	28
3.2 Construction de régions	44
3.3 Conclusion	47

L'EMPLOI de la couleur en segmentation d'images est devenu très populaire depuis l'avènement du multimédia grand public. La couleur étant une information que l'on attache directement à une région, de nombreux auteurs ont pensé qu'une segmentation couleur rendrait ces régions plus significatives et in fine apporterait des améliorations en terme de segmentation d'objets.

Nous suivons ici le plan de présentation tel qu'on le trouve dans le livre d'ALAIN TRÉMAU, CHRISTINE FERNANDEZ-MALOIGNE ET PIERRE BOTON [TRÉMEA04] et qui réalise une étude bibliographique détaillée. Nous allons alors présenter dans ce chapitre, un état de l'art non exhaustif des principales méthodes de segmentation d'images couleur à savoir : les méthodes de classification pixellaires et les méthodes de construction de régions. Aussi, nous ne perdrons pas de vue qu'aucune méthode de segmentation n'est valable pour tout type d'image et que la connaissance à priori de l'image et du but recherché sont deux critères prépondérants dans le choix de la méthode à utiliser (présence ou non de texture ou de bruit, choix de l'espace couleur et de la métrique, extraction de contours ou de régions). Nous nous basons donc sur les précédents travaux de LEZORAY [LEZORA00A] effectués dans le même domaine d'application que nous privilégions c'est-à-dire le biomédical, pour avoir choisi de détailler certains algorithmes que nous utiliserons dans le chapitre 5. Nous présenterons également les précautions à prendre dans le choix de certains paramètres de la classification pixellaire ainsi que dans la construction des différentes bases d'images. Enfin nous illustrerons certains résultats d'algorithmes sur des images microscopiques de cellules de tumeurs bronchiques.

La segmentation consiste à partitionner une image en régions homogènes c'est-à-dire en un ensemble connexe de points de l'image ayant des propriétés communes. Cette étape primordiale dans le processus de traitement et d'analyse d'images couleur fait référence à l'extraction de primitives suivant deux approches que l'on nomme usuellement : approche région et approche contour. Nous rappelons brièvement ci-dessous les différences entre ces deux notions :

1. La notion de « contour » est associée à la recherche de discontinuités locales, de transitions entre différentes zones où certains paramètres comme la couleur, l'inten-

sité, la texture ne sont pas identiques. Mais cette notion de contour ne permet pas d'obtenir directement une segmentation de l'image telle que nous l'avons présentée ci-dessus. En effet, il est assez rare d'obtenir directement après traitement, des contours entièrement connectés et il est alors indispensable de fermer ces contours pour pouvoir ensuite assimiler les régions aux zones à l'intérieur d'une ligne fermée ;

2. La notion de « région » est associée à des regroupements de pixels connexes ayant des attributs communs (couleur, texture, etc). Ces méthodes aboutissent directement à une partition de l'image où chaque pixel est affecté à une région unique. Selon la définition de ZUCKER, la segmentation d'une image A définie sur un ensemble de sites S est une partition de S en sous-ensembles disjoints non vides $\{R_i\}$ pour $i = \{1, 2, \dots, M\}$ appelés régions contenant des sites connexes au sens d'un prédicat et tels que :

$$S = \bigcup_{i=1}^M R_i$$

Nous commençons par présenter ci-dessous différentes techniques de classification pixellaire utilisées dans un cadre de segmentation d'images couleur. Notons toutefois que ces méthodes qui consistent à effectuer un découpage dans l'espace des paramètres caractéristiques, ne peuvent pas être considérées comme des techniques de segmentation au sens strict du terme. En effet utilisées comme telles, elles ne vérifient pas tous les prédicats d'une segmentation comme celui de la connexité. Nous insistons donc sur le fait qu'elles ne constituent que des techniques de pré-segmentation et qu'il est par conséquent nécessaire de les coupler à d'autres techniques (comme nous le ferons dans la suite de ce manuscrit) afin d'obtenir une segmentation complète satisfaisant tous les prédicats.

3.1 La classification pixellaire

De nombreux travaux sur la classification de pixels qui consiste à affecter à chaque pixel de l'image une classe qui définit les régions à extraire de l'image, ont vu le jour [CELENK90, ROBINS98, ALTUNB98, PAPAS92, OHTA80, SOILLE96, PARK98]. Nous présentons dans cette section trois techniques de classification pixellaire permettant la construction de classes de pixels. Les deux premières techniques correspondent à une classification par histogrammes (1D et 3D) et la troisième correspond à une classification par clustering. Nous entrerons plus en détails dans la classification par clustering en présentant différents algorithmes de classification de pixels « non-supervisées » ou « supervisées ».

3.1.1 Définition d'un classifieur

Un classifieur désigne tout outil de reconnaissance qui pour un vecteur reçu en entrée, donne des informations sur sa classe d'appartenance. Cet outil peut s'écrire sous la forme d'une fonction e , qui à l'aide de descripteurs d'un vecteur x à reconnaître, attribue à x la classe C_i parmi k classes possibles ($i \in [1, k]$). Nous pouvons alors définir un classifieur par la relation suivante où l'ensemble $K = \{C_1, \dots, C_k\}$:

$$e : x \in R^n \longrightarrow K \quad (3.1)$$

Les réponses fournies par un classifieur e qu'il soit non-supervisé ou supervisé peuvent être classées en trois catégories :

1. Type classe : $e(x) = C_i$, indique que le classifieur a attribué la classe C_i à x ;
2. Type rang : $e(x) = [r_1^j, \dots, r_k^j]$, où r_i^j est le rang attribué à la classe i par le classifieur j ;
3. Type mesure : $e(x) = [m_1^j, \dots, m_k^j]$, où m_i^j est la mesure attribuée à la classe i par le classifieur j .

Dans tout ce chapitre, la réponse fournie directement en sortie de classification pixellaire sera considérée de type classe. Nous obtenons alors via une classification de pixels non-supervisée ou supervisée, pour chaque pixel de l'image, sa classe d'appartenance parmi les classes disponibles.

3.1.2 Classification à partir d'histogrammes 1D, 2D et 3D

La classification par histogrammes 1D est une technique couramment utilisée dans la segmentation d'images couleur car elle présente l'avantage de ne pas nécessiter de connaissance a priori sur l'image. Les méthodes d'analyse d'histogrammes se différencient par l'espace couleur choisi ou la composante couleur la plus significative, la détection des modes principaux et le critère d'arrêt de l'analyse récursive d'histogramme [SCHETT93, LAMBER00]. Les deux approches utilisées pour cette analyse sont l'analyse récursive des histogrammes 1D des composantes couleur et l'analyse hiérarchique des histogrammes 1D que nous détaillons ci-dessous :

L'analyse récursive des histogrammes met en évidence au fil des itérations, les modes correspondant aux classes de pixels. La plupart des méthodes que l'on peut trouver dans la littérature supposent que la distribution des couleurs de chaque région est de type gaussienne. Ces méthodes se différencient par le choix des composantes couleur utilisées, la détermination de la composante la plus représentative, les critères d'arrêt, ainsi que la méthode et les critères d'extraction des modes. Nous pouvons citer quelques travaux relatifs à ce type d'analyse : CELENK [CELENK90] modélise les objets de l'image dont nous n'avons aucune information colorimétrique par des portions de cylindres correspondant aux largeurs de différents pics déterminés dans les histogrammes 1D. L'algorithme de OHLANDER suppose que chaque région est représentée par un mode de l'un des neuf histogrammes 1D correspondant aux neuf composantes issues de trois espaces couleur que sont RGB , YIQ , LTS . La segmentation qui y est liée est obtenue par un seuillage itératif effectué à chaque étape sur une composante déterminée par la présence ou non de pic prédominant séparable sur son histogramme [OHLAND78]. OHTA ET AL. [OHTA80] utilisent l'analyse d'histogramme 1D pour la segmentation d'images dans différents espaces couleur et montrent que cette technique est plus efficace lorsque les composantes couleurs sont décorréélées. L'algorithme de TOMINAGA [TOMINA92] utilise cette méthode d'analyse récursive d'histogrammes en adaptant l'espace de représentation

de la couleur aux données. Une transformation de KARHUNEN-LOÈVE est alors effectuée à chaque étape afin de rechercher des axes de projection pour lesquelles la dispersion des points relatif à la couleur des pixels est maximal. L'algorithme de SCHETTINI [SCHETT93] utilise un multiseuillage suivi d'une fusion de région et l'analyse récursive des histogrammes consiste à extraire séquentiellement, par la technique du scale space filtering (filtrage espace-échelle), le mode le plus important parmi les trois histogrammes des composantes L^* , u^* et v^* . BUSIN ET AL. [BUSIN04A, BUSIN04B] proposent de choisir différents espaces de représentation couleur dans lesquels les pixels appartenant aux modes des histogrammes 1D présentent des propriétés de connexité de sorte que chaque mode corresponde effectivement à une région spatialement cohérente dans l'image.

La segmentation d'image couleur peut également se faire par analyse hiérarchique des histogrammes 1D. A ce titre, nous présentons brièvement la méthode de CHENG ET SUN [CHENG00]. Les auteurs définissent une mesure d'homogénéité prenant en compte l'information colorimétrique locale et globale et effectuent ensuite une analyse spatiale de l'image segmentée. Une division de chaque région en sous-régions de teinte uniforme est effectuée dans le cas où le nombre de modes de l'histogramme est supérieur à un. Une étape de fusion de sous-régions adjacentes possédant des attributs proches est ensuite effectuée de sorte à éviter toute sur-segmentation.

L'utilisation de classification par histogrammes 3D semble plus appropriée à la segmentation d'images couleur que celle par histogrammes 1D [PETROU98]. En effet, l'information couleur étant tridimensionnelle, une classe de pixels séparable dans un espace couleur à trois dimensions peut ne pas l'être par la projection selon une composante. Mais à contrario, la couleur d'un pixel étant généralement codée sur 256^3 valeurs, l'histogramme 3D d'une image couleur requiert alors une place mémoire importante. Ceci explique que peu d'auteurs se soient intéressés à une analyse sur ce type de classification. Néanmoins, nous pouvons citer quelques travaux qui ont vu le jour et supposer que l'évolution grandissante de la puissance de calcul de nos ordinateurs peut nous amener dans quelques années à revenir sur une classification par histogrammes 3D. Une méthode d'analyse introduite par RAFFY [RAFFY99] consiste à binariser les cellules de sorte à isoler les cellules de fortes densités de probabilités (étiquetées 1) estimée à l'aide d'un seuil portant sur les populations de cellules. Chaque groupe de cellules connexes dans l'histogramme étiquetées 1 constitue une classe. L'inconvénient de cette méthode réside dans la difficulté du choix du seuil fixé par l'utilisateur. PARK ET AL. [PARK98] quant à eux, utilisent des opérateurs morphologiques pour détecter les modes de l'histogramme 3D. Une fermeture morphologique binaire est effectuée sur l'histogramme préalablement seuillé afin de déterminer les noyaux des classes qui subiront ensuite plusieurs dilatations de sorte à retrouver la forme des nuages correspondant aux classes. Pour finir, les pixels dont les couleurs se situent dans un nuage sont assignés à la classe correspondante. GERAUD [GÉRAUD01] propose une méthode de classification non supervisée basée sur un histogramme 3D. L'algorithme consiste dans un premier temps à modifier la dynamique de l'histogramme 3D de l'image couleur afin de rehausser les valeurs faibles de celui-ci. Après avoir inversé l'histogramme 3D, un filtre gaussien 3D est exécuté dans le but de lisser l'histogramme et de supprimer les principaux minima locaux. Pour supprimer les minima locaux résiduels, une saturation des niveaux des régions de plus fortes valeurs est effectuée et suivie d'une fermeture morphologique. Pour finir, une Ligne de Partage des Eaux est effectuée. Nous pouvons noter que le temps de traitement de cette méthode pourrait être améliorée en utilisant non plus

un espace 3D des couleurs mais trois projections 2D de cet espace [XUE03]. Différents travaux de LEZORAY [LEZORA03A, LEZORA03B, LEZORA04] traitent des histogrammes 2D dans le cadre de la segmentation d'images couleur. Dans [LEZORA04], l'auteur propose une approche de coalescence non supervisée d'histogrammes 2D basée sur une stratégie morphologique ayant pour but de diviser l'image en un nombre de classes non fixé au préalable.

3.1.3 Classification par clustering

Les méthodes de classification par clustering présentent l'espace couleur en sous-espaces homogènes selon un critère de ressemblance des couleurs de pixels. Ces méthodes analysent, dans l'espace couleur considéré, les nuages formés par les points associés aux pixels et tentent de retrouver k nuages correspondant aux k classes de pixels de l'image [CAMPAD97, LITTMAN97, SAMMOU97]. Différents algorithmes de classification de pixels existent dans la littérature et sont généralement utilisés dans le but d'obtenir un prétraitement pour une croissance de régions. Les réseaux de neurones sont très souvent utilisés pour leur bons résultats, mais nous nous attacherons à présenter des algorithmes qui en plus de donner des résultats satisfaisants dans de nombreuses applications offrent l'avantage d'être faciles d'utilisation. Nous pouvons donc citer des algorithmes de classification de pixels non-supervisés comme les k -moyennes proposée par MAC QUEEN [MACQUE67], C -moyennes floues [LIM90, COCQUE95], Fisher [FISHER36, FISHER58] ou bien des algorithmes de classification de pixels supervisée comme celui de Bayes [COCQUE95], les Réseaux de Neurones Multi-Couches, les Machines à Supports de Vecteurs (SVM) ou encore les k plus proches voisins (k -PPV).

3.1.4 Classification de pixels non supervisée

La classification de pixels non supervisée appelée aussi classification de pixels sans apprentissage consiste à découper l'espace de représentation en zones homogènes selon un critère de vraisemblance entre les individus. Cette approche est utilisée pour effectuer une classification de pixels en aveugle c'est-à-dire sans connaissance a priori sur l'image et ne nécessite donc pas de phase d'apprentissage. Néanmoins, la première partie de cette thèse s'articulant autour d'images numériques couleur et ayant pour application l'imagerie microscopique biomédicale où la principale information dont nous disposons est la couleur, cette information sera utilisée comme critère de vraisemblance.

Nous présentons sur la figure 3.1 à titre d'illustration, les résultats d'une quantification en 4 couleurs avec deux algorithmes de classification de pixels non supervisés différents afin de nous rendre compte de la diversité des résultats selon l'algorithme choisi.

Nous allons à présent détailler trois des algorithmes de classification de pixels non supervisée à savoir :

1. L'algorithme des k -moyennes ;
2. L'algorithme des C -moyennes floues ;
3. L'algorithme de Fisher.

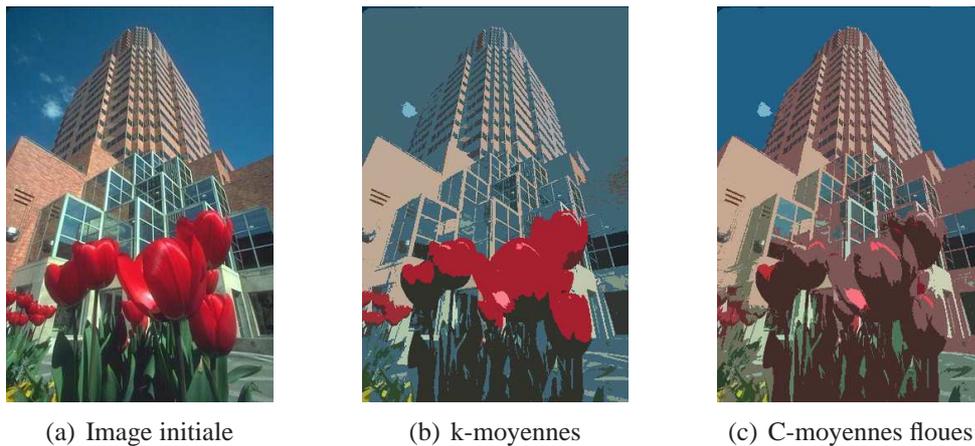


FIG. 3.1 – Quantification en 4 couleurs avec différents algorithmes de classification de pixels non supervisés.

3.1.4.1 Algorithme des k-moyennes

L'algorithme des k-moyennes (*k-means*) [MACQUE67] réalise un partitionnement automatique des pixels de l'image en k classes homogènes. Lors de la phase d'initialisation, c'est à dire pour $t = 0$, nous choisissons les p référents initiaux de manière aléatoire et fixons le nombre maximal d'itérations de l'algorithme. Chaque classe C_k ayant n_k membres est alors définie par son centre de gravité selon la relation suivante :

$$w_k = \frac{1}{n_k} \sum_{z \in C_k} z \quad (3.2)$$

A l'étape suivante (c'est-à-dire à l'itération t), l'ensemble des référents W^{t-1} de l'étape précédente est connu. Nous découpons alors cette étape en deux phases étant respectivement une phase d'affectation et une phase de minimisation :

1. Durant la phase d'affectation, une mise à jour de la fonction d'affectation χ associée à W^{t-1} est effectuée. Pour un ensemble W de référents fixe, la minimisation de I par rapport à χ s'obtient en affectant chaque observation z au référent w_c selon la nouvelle fonction d'affectation χ tel que :

$$\chi(z) = \underset{l}{\operatorname{argmin}} \|z - w_r\|^2 \quad (3.3)$$

2. Durant la phase de minimisation, nous calculons des nouveaux référents W^t en appliquant l'équation de re-calculation des centres.

Ces deux phases faisant partie de l'étape itérative, elles sont répétées jusqu'à ce que l'on atteigne un nombre maximal d'itérations ou une stabilisation de I .

La figure 3.2 illustre le déroulement étape par étape d'un tel algorithme. Lors de la phase d'initialisation, un pixel est sélectionné de façon aléatoire parmi l'ensemble des pixels de l'image afin de représenter son centre de gravité initial et ce pour chaque classe (figure 3.2(a)). L'algorithme affecte ensuite à chaque pixel de l'image la classe C_i dont le

centre de gravité (calculé par une norme L_2) est le plus proche (figure 3.2(b)). A chaque fois qu'un pixel de l'image est affecté à sa classe respective, le centre de gravité de la classe est recalculé (figure 3.2(c)). Ce processus est réitéré jusqu'à convergence de l'algorithme c'est à dire jusqu'à l'obtention d'un minimum local de la somme des distances de normes L_2 entre les points de chaque classe et son centre de gravité (figure 3.2(d)). Il existe des versions améliorées des k-moyennes telles que l'algorithme LBG (Linde, Buzo et Gray) [LINDE80].

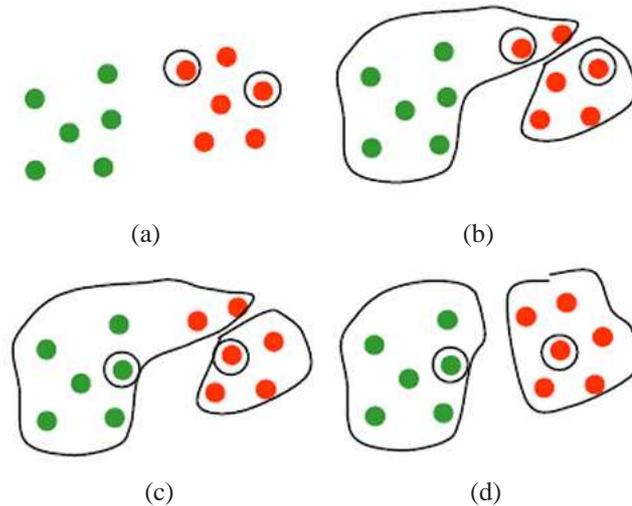


FIG. 3.2 – Approche de l'apprentissage.

Mais les résultats de classification établis par l'algorithme des k-moyennes peuvent fluctuer selon les paramètres d'entrés qui sont :

- le paramètre k correspondant au nombre de classes fixé par l'utilisateur. Ce paramètre peut être fixé de deux manières possibles : soit en utilisant des connaissances à priori sur l'image à traiter, soit de manière empirique en essayant différentes valeurs de k et en choisissant celle qui maximise un critère de qualité du clustering obtenu. Notons que cette dernière méthode sera utilisée dans la partie classification pixellaire traitée dans la chapitre suivant. La figure 3.3 illustre le résultat de la classification sur une partie d'une image de microscopie bronchique pour différentes valeurs de k . Nous pouvons constater qu'une valeur de k plus élevée (ex. $k = 4$) que le nombre de classes désirées en sortie (ex. $k = 2$) entraîne une classification plus fine.
- la position initiale des centres de gravité des différentes classes. Dans de nombreux cas, les centres de gravité des classes sont initialisés de façon aléatoire, mais une alternative consiste à les fixer manuellement à une valeur proche des couleurs moyennes des pixels de chaque région. Cette alternative évite par exemple d'obtenir une classe vide si la position initiale de son centre de gravité est trop isolée dans l'espace des couleurs. A contrario, cela peut engendrer (surtout dans le cas d'utilisation d'images réelles) des erreurs de classification pouvant être dues au recouvrement des distributions colorimétriques de certaines régions. A titre d'illustration, nous montrons sur la figure 3.4 que les points sont situés près de l'axe du luminance (la corrélation entre composante est élevée) et donc qu'il est assez difficile de fixer manuellement le centre de gravité de certaines classes pour des images microscopiques

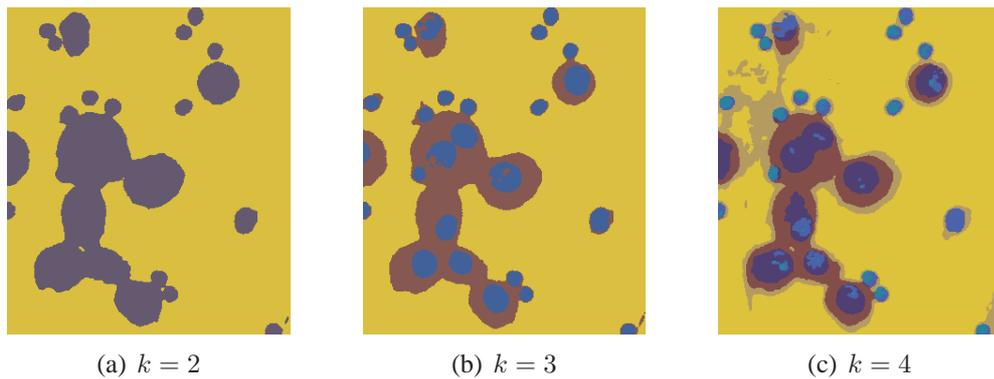
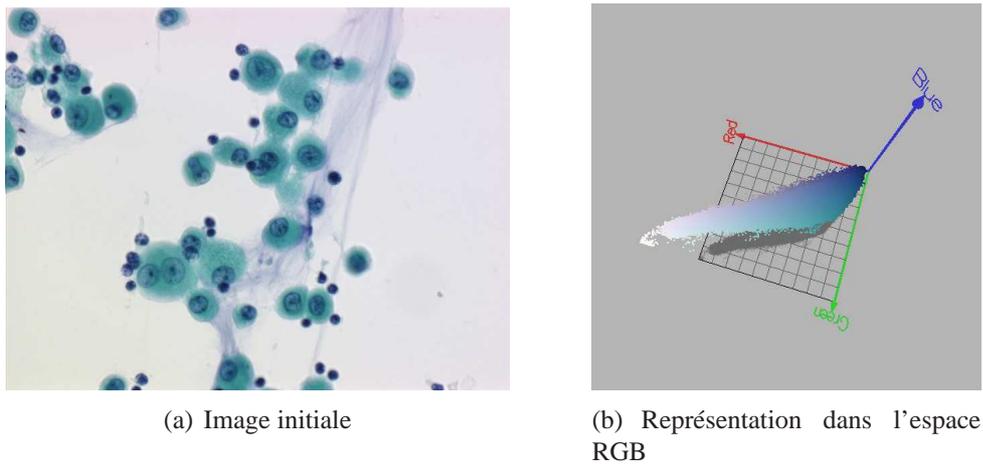


FIG. 3.3 – Visualisation du nombre de classes.

de tumeurs bronchiques du fait de la superposition de certains « nuages de points » représentant la répartition des pixels dans un espace colorimétrique (un recouvrement entre le mucus et le noyau d'une part et le cytoplasme et le noyau d'autre part est toujours existant). A l'initialisation, les k centroides seront donc répartis sur cet axe de luminance à une distance de $255/k$ sur les trois composantes.

FIG. 3.4 – Représentation d'une image dans l'espace RGB .

La figure 3.5 illustre une classification pixellaire effectuée par l'algorithme des k -moyennes sur deux images d'une base de tests.

3.1.4.2 Algorithme des C-moyennes floues

L'algorithme des C-moyennes floues (*Fuzzy C-means*) [LIM90, COCQUE95] diffère peu de l'algorithme des k -moyennes si ce n'est qu'il est basé sur une classification floue. Il n'associe pas directement une classe C_i à un pixel x de l'image mais plutôt un degré d'appartenance à une classe (compris entre 0 et 1). Il est basé sur l'optimisation d'un critère quadratique où la somme des écarts quadratiques intra-classes $J(m)$ telle qu'elle est définie dans l'équation ci-dessous doit être minimale. Les deux paramètres d'entrées de cet algorithme devant être définis au préalable sont respectivement le paramètre de flou m et le nombre de classes k_w (ici le nombre de classes doit être supérieur ou égal à 3). Mais

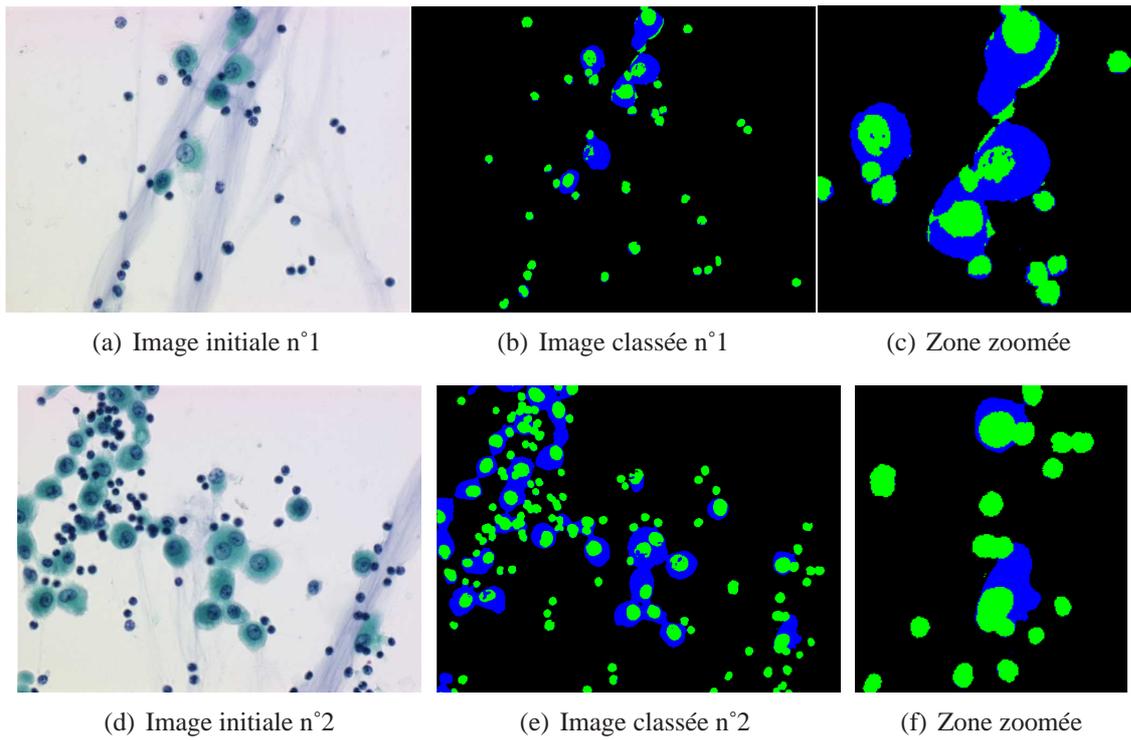


FIG. 3.5 – Classification pixellaire par l'algorithme des k-moyennes.

notons que FRIGUI ET KRISHNAPURAM [FRIGUI96] proposent une méthode permettant de trouver automatiquement le nombre de classes.

$$J(m) = \sum_x \sum_{j=1}^{k_w} (U_j(x))^m d(\overline{B}_j, B(x)) \quad (3.4)$$

avec $U_j(x)$ désignant le degré d'appartenance du pixel x à la classe w_j donné par :

$$U_j(x) = \frac{\left(\frac{1}{d(B(x), \overline{B}_j)^{\frac{1}{m-1}}} \right)}{\left(\frac{1}{\sum_{i=1}^{k_w} d(B(x), \overline{B}_i)^{\frac{1}{m-1}}} \right)}$$

où le centre de gravité \overline{B}_j relatif à la classe w_j est donné par la relation suivante :

$$\overline{B}_j^W = \frac{\sum_x (U_j(x))^m \cdot B^W(x)}{\sum_x (U_j(x))^m}$$

où W représente la composante couleur.

3.1.4.3 Algorithme de Fisher

L'algorithme de Fisher [FISHER36, FISHER58] consiste à effectuer une classification de pixels de l'image en k classes, en utilisant le partitionnement d'un histogramme de niveaux de gris en k classes disjointes tel que la somme des variances des classes soit minimale. Dans le cadre de la couleur, il convient d'appliquer cet algorithme séparément sur les trois composantes de l'espace de représentation couleur. La figure 3.6 illustre une classification pixellaire effectuée par l'algorithme de Fisher sur la composante L de l'espace HSL et sur deux images d'une base de tests.

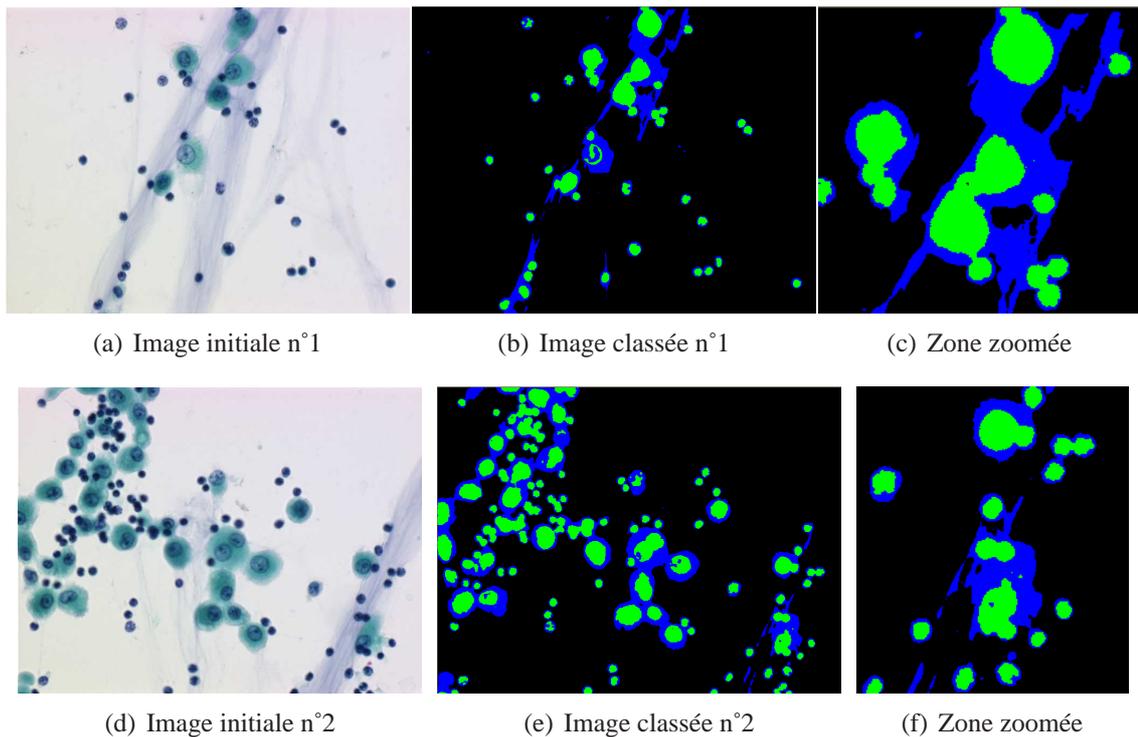


FIG. 3.6 – Classification pixellaire par l'algorithme de Fisher sur la composante L de l'espace HSL .

3.1.5 Classification de pixels supervisée

La classification de pixels supervisée appelée aussi classification de pixels avec apprentissage consiste à définir une fonction de discrimination effectuant un découpage de l'espace de représentation à partir d'une connaissance a priori de l'image. Ce type de classification nécessite la création d'une base d'apprentissage faisant intervenir une segmentation de référence. La taille de cette base d'apprentissage doit être choisie avec précaution. En effet, l'augmentation de la taille de cette base pour certains algorithmes comme celui des SVM ou des k -PPV améliore très légèrement le taux de classification comme le montre le tableau 3.1 mais entraîne en contre partie un temps d'apprentissage prohibitif et la complexité de la fonction de décision produite devient alors très gourmande en temps de calcul. Les valeurs données dans ce tableau représentent des indices de qualité sur la reconnaissance du cytoplasme et du noyau calculés à partir d'une méthode d'évaluation spécifique à la microscopie et qui sera détaillée dans le chapitre 4.

Base d'apprentissage	$Indice_{cytoplasme}$	$Indice_{noyau}$
Base n°1 (334 exemples)	77.4 %	74.2 %
Base n°2 (1002 exemples)	78.2 %	75 %

TAB. 3.1 – Influence du nombre d'exemples dans la base d'apprentissage avec l'algorithme des SVM dans l'espace de représentation RGB .

3.1.5.1 Algorithme des k-plus proches voisins

La méthode des k-plus proches voisins (k-PPV) est une méthode d'estimation non paramétrique de densité [MICHIE94, DUDA01]. Elle consiste à rechercher à partir d'une base d'apprentissage et d'une distance définie sur « l'espace des données » les K plus proches voisins d'un élément. Ce qui revient à calculer l'estimation de densité r_i de la classe C_i au point x défini par la relation suivante :

$$r_i(x) = \frac{k_i(x)}{n_i \times V(x)} \quad (3.5)$$

où $k_i(x)$ est le nombre de points de C_i appartenant aux k-PPV de x , n_i est le cardinal de la classe C_i et $V(x)$ le volume de la plus petite boule contenant le k-PPV de x . La probabilité d'appartenance à une classe de cet élément x est alors proportionnelle au nombre d'exemples de cette classe parmi ses k-PPV. La classe de l'élément x est alors celle ayant la plus grande probabilité. Les résultats dépendent fortement de la valeur de k , il convient de choisir une valeur minimisant le risque d'erreur déterminé à partir d'une base de tests.

La figure 3.7 illustre une classification pixellaire effectuée par l'algorithme des k-PPV sur deux images d'une base de tests.

3.1.5.2 Algorithme de Bayes

Cet algorithme de classification est basé sur la théorie de décision Bayésienne [COCQUE95]. La méthode utilisée est une approche statistique supposant que le problème de classification peut être exprimé en termes probabilistes. L'hypothèse de base est généralement que la fonction de densité de probabilité d'un pixel x d'appartenir à une classe C_i est de forme gaussienne. L'algorithme de Bayes cherche à déterminer pour chaque élément x la classe C_i qui maximise la probabilité de contenir cet élément.

$$f(x, C_i) = -\frac{1}{2} (x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i) - \frac{1}{2} \log |\Sigma_i| - \log p_i + \frac{k}{2} \log 2\Pi \quad (3.6)$$

où k est le nombre de classes, μ_i la moyenne des éléments de la classe C_i , Σ_i la matrice de variance-covariance et p_i la probabilité a priori de la classe C_i .

La figure 3.8 illustre une classification pixellaire effectuée par l'algorithme de Bayes sur deux images d'une base de tests.

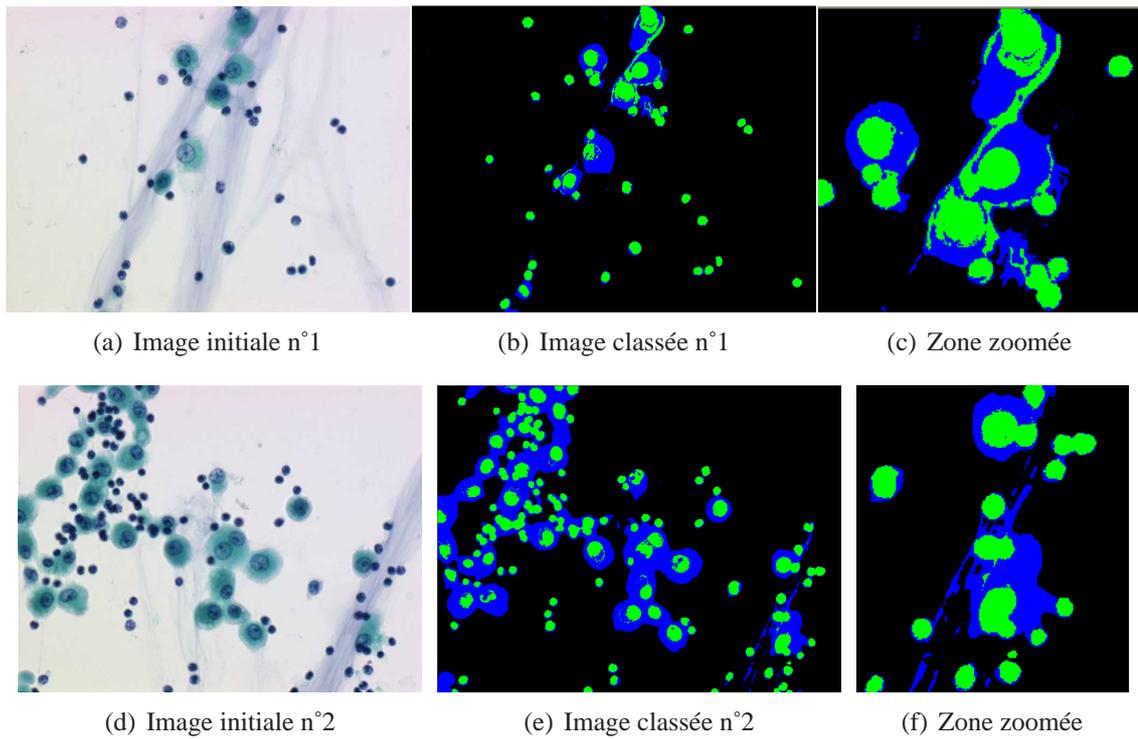


FIG. 3.7 – Classification pixelaire par l'algorithme des k-PPV.

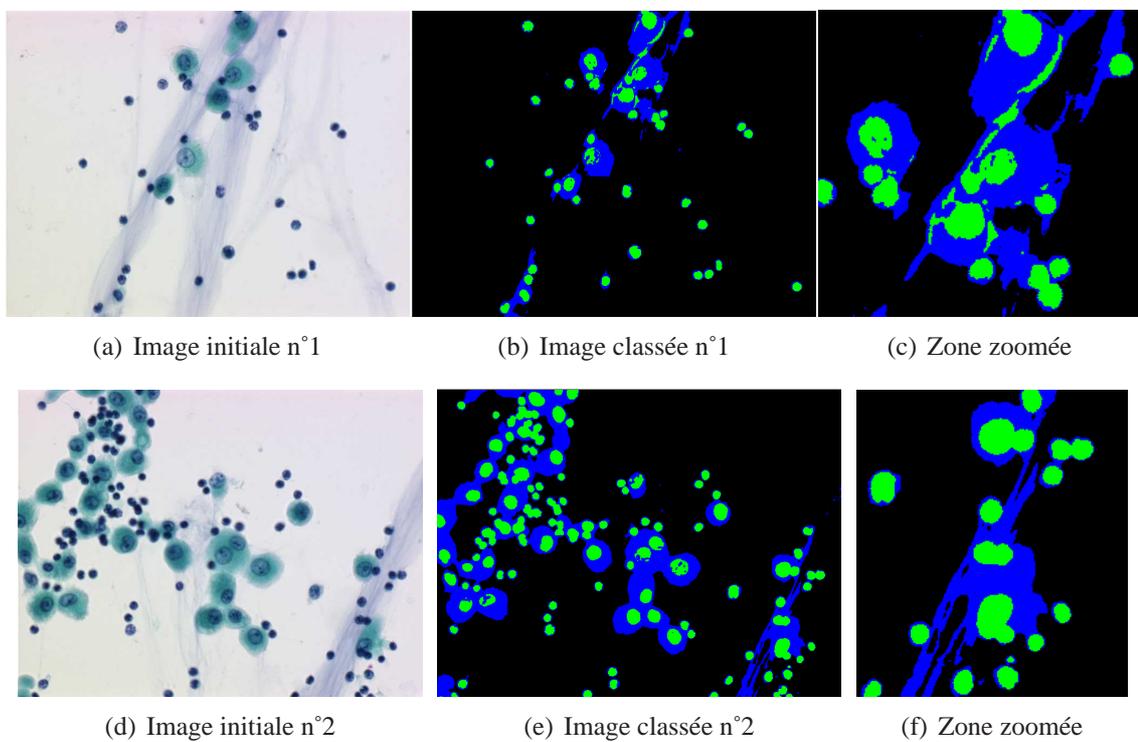


FIG. 3.8 – Classification pixelaire par l'algorithme de Bayes.

3.1.5.3 Algorithme des Machines à support de vecteurs

Les méthodes des Machines à support de vecteurs (*Support Vector Machines : SVM*) ont reçu une attention considérable ces dernières années et un grand nombre d'applications sont décrites dans la littérature [CRISTI00, DONG05, CHRIST05, CANU02]. L'objectif des SVM est de maximiser la marge de séparation entre les classes. Une marge importante implique une faible dimension de VAPNIK ET CHERVONENKIS [VAPNIK71], qui a pour conséquence de bonnes performances en généralisation. Les SVM sont des algorithmes d'apprentissage faisant l'hypothèse que les éléments sont linéairement séparables s'ils sont préalablement projetés dans un espace à grande dimension adéquat. La projection est réalisée par l'utilisation de fonctions kernel $k(\cdot, \cdot)$. La fonction la plus utilisée est le noyau gaussien qui réalise cette projection de façon implicite [VAPNIK98].

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (3.7)$$

La recherche du meilleur hyperplan de séparation peut alors se formaliser comme un problème de programmation quadratique sous contrainte linéaire. L'hyperplan fournit par les SVM est ainsi représenté comme une combinaison linéaire de certains exemples de la base d'apprentissage appelés vecteurs de support.

Il existe plusieurs algorithmes pouvant résoudre le problème cité ci-dessus. Le plus compétitif étant actuellement l'algorithme Séquentiel Minimal Optimisation (Optimisation Minimum Séquentiel) [PLATT98]. Il reste deux hyper-paramètres (C et σ) qui doivent être choisis afin de minimiser le risque d'erreur déterminé à partir d'une base de tests. L'algorithme produit alors une fonction de décision pouvant être formalisée comme ci-dessous [VAPNIK98].

$$\varphi(x) = \sum_{i \in SV} \alpha_i y_i k(x_i, x) + b \quad (3.8)$$

où $0 \leq \alpha_i \leq C$ et (x_i, y_i) est un exemple de la base de tests (l'influence du nombre d'exemple dans la base de tests ou d'apprentissage est montrée dans le tableau 3.1.

La figure 3.9 illustre une classification pixellaire effectuée par l'algorithme des SVM sur deux images d'une base de tests.

3.1.5.4 Algorithme des Réseaux de Neurones Multi Couches

Les réseaux de neurones que nous avons utilisés sont des réseaux de neurones multi-couches avec rétro-propagation de l'erreur du gradient (*MLP : Multi Layer Perceptron*) [RUMELH86]. Ils sont utilisés depuis de nombreuses années dans le domaine de la classification étant donné leurs bons résultats. L'idée principale des MLP est de grouper des neurones par couche et de connecter complètement les neurones des couches adjacentes. Typiquement, les couches sont organisées de la façon suivante : une couche d'entrée (paramètres caractérisant un objet), une ou plusieurs couches cachées (augmentant les possibilités d'apprentissage), et une couche de sortie (fournissant la classe trouvée pour un objet).

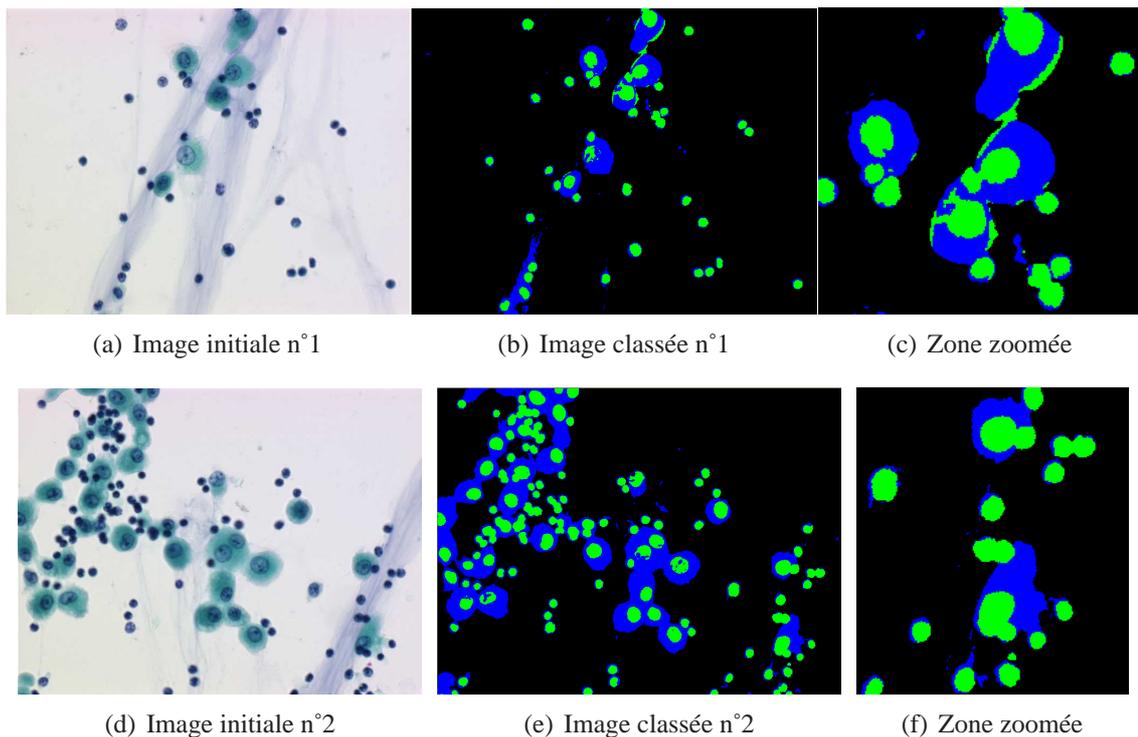


FIG. 3.9 – Classification pixelaire par l'algorithme des SVM.

La phase d'apprentissage consiste à modifier les poids reliant les neurones de façon à ce que la classe en sortie corresponde à celle de l'objet présenté en entrée. Cette modification est effectuée par un algorithme de rétro-propagation [HÉRAUL94]. Afin d'obtenir une bonne généralisation, il reste deux paramètres à régler : la durée de l'apprentissage et le nombre de neurones cachés. Ils sont choisis de façon à minimiser le risque d'erreur déterminé à partir d'une base de tests.

La figure 3.10 illustre une classification pixelaire effectuée par l'algorithme des Réseaux de Neurones Multi Couches sur deux images d'une base de tests.

3.1.6 Précautions liées à l'utilisation de la classification pixelaire

La difficulté de la classification pixelaire réside en partie dans le choix du nombre de classes pour extraire de façon précise les différents objets jugés importants d'une image. Une connaissance à priori de l'image ou de l'application est donc un facteur intéressant pour la détermination de ce paramètre. Il est toujours possible de choisir un nombre de classes plus important et de fusionner ensuite certaines classes afin de revenir au nombre d'objets extraits désiré par une classification ascendante hiérarchique. A titre d'illustration, nous montrons sur la figure 3.11, différents résultats d'une classification pixelaire par l'algorithme des k-moyennes sur des images microscopiques cellulaires et ce en fonction du nombre de classes choisi. Pour ce type d'application, une connaissance de l'image est indispensable puisque le but de cette classification pixelaire est d'extraire trois types d'objets dans l'image qui correspondent au fond, et aux deux constituants cellulaires : le

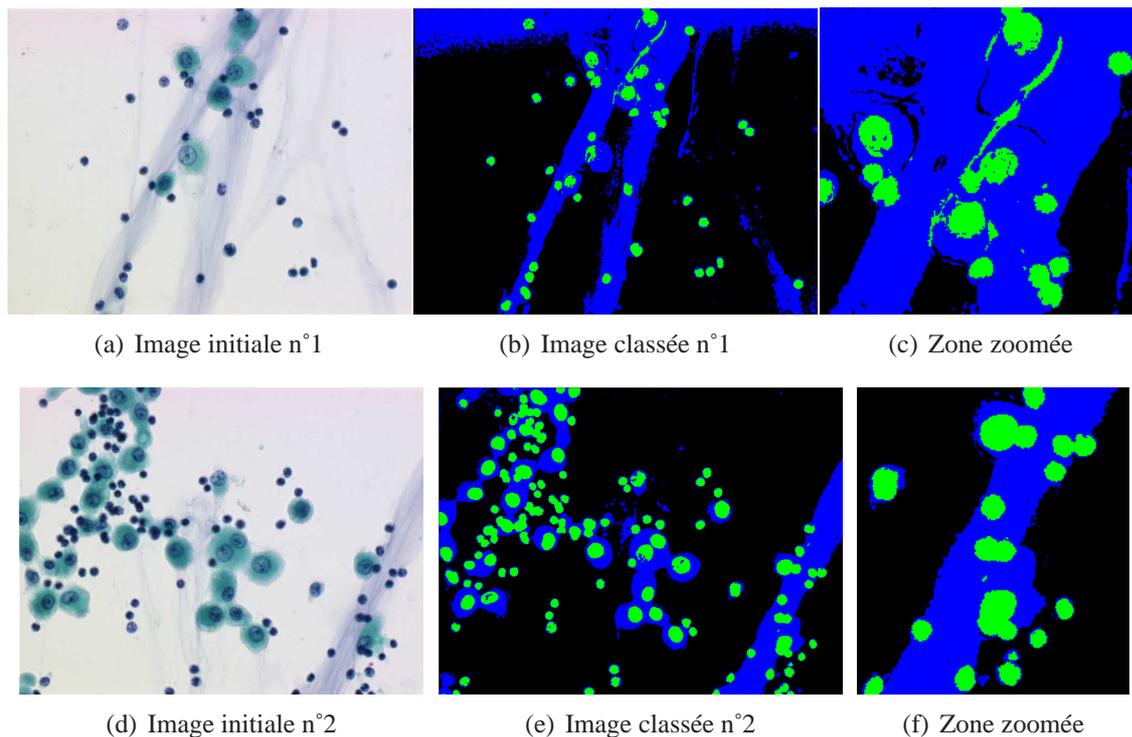


FIG. 3.10 – Classification pixellaire par l’algorithme des RNMC.

cytoplasme et le noyau. Pour ce faire, il est alors indispensable de fixer le paramètre du nombre de classes supérieur ou égal à trois.

Une attention particulière devra également être apportée à la création de la base d’apprentissage principalement rencontrée dans le cadre d’une classification de pixels supervisée. En effet, ce type de classification comme nous pourrons le voir ultérieurement nécessite deux types de bases : une base d’apprentissage et une base de test.

1. La base d’apprentissage est généralement construite à partir de plusieurs images contenant des objets d’une grande variabilité et segmentés manuellement par un ou plusieurs experts. Cette expertise permet d’attribuer une classe à chaque pixel de l’image de sorte que le système puisse effectuer un apprentissage de l’image et in fine soit en mesure d’associer de façon plus sûre une classe à un pixel non appris. La base d’apprentissage est habituellement générée à partir de tous les pixels de l’image mais les temps de généralisation et de traitement sur une telle base en utilisant des algorithmes comme les « Machines à Support de Vecteurs » ou les « k-PPV » peuvent être considérables ;
2. La base de tests est généralement construite à partir de plusieurs images contenant des objets d’une grande variabilité. Cette base de tests est utilisée dans le but de tester les algorithmes de classification de pixels. Bien qu’elle soit utilisée dans le cadre de classification pixellaire non-supervisée, cette base est particulièrement adaptée à la classification de pixels supervisée puisqu’elle permet de tester les algorithmes sur des images qui n’ont pas été apprises par le système.

Il est alors conseillé pour cette démarche d’utiliser des images représentatives mais variées de sorte à ce que le système puisse apprendre tous les types d’objets sans en omettre

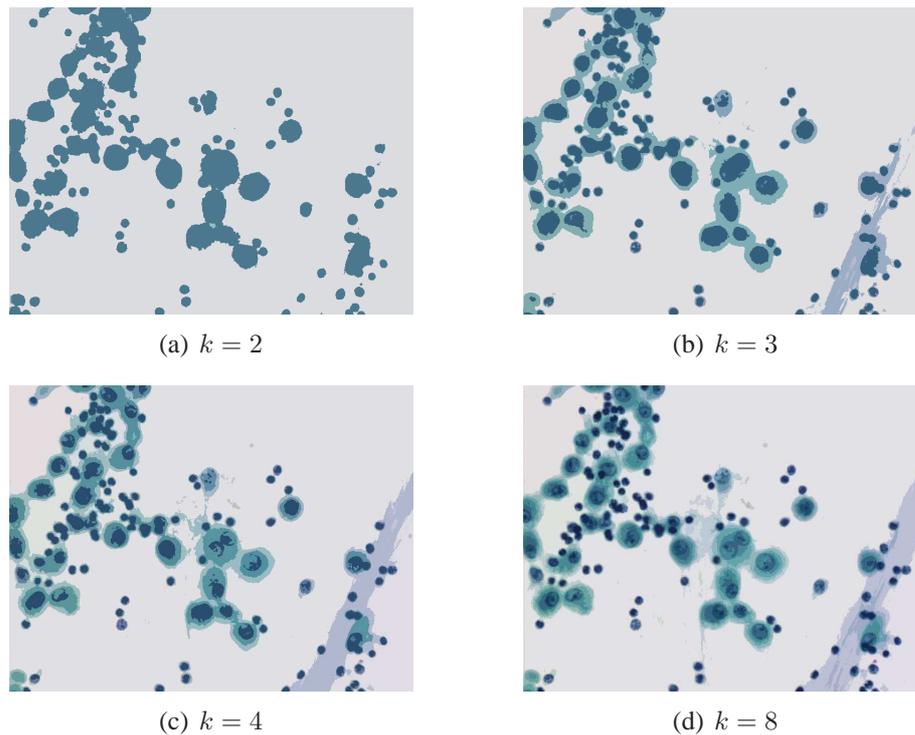


FIG. 3.11 – Résultats de plusieurs classifications pixelaire par l'algorithme des k-moyennes avec un nombre de classes différent pour chaque image.

et permettre ainsi d'obtenir de bons taux de reconnaissance sur des images inconnues. En illustration, nous montrons sur la figure 3.12, une base d'apprentissage d'images microscopiques biomédicales et sur la figure 3.13, une base de tests correspondante. Nous insistons sur le fait que les différents types d'objets rencontrés qu'ils soient désirables ou non à l'extraction sont présent dans les deux bases et que la proportion de types d'objets différents est équivalente dans les deux bases comme l'illustre le tableau 3.2.

Type de base	$Indice_{fond}$	$Indice_{cytoplasme}$	$Indice_{noyau}$
Base d'apprentissage	89,6 %	6,6 %	3,7 %
Base de tests	89 %	7,1 %	3,9 %

TAB. 3.2 – Statistiques de répartitions des pixels par type d'objet sur les différentes bases.

3.1.7 Classification spatio-colorimétrique des pixels

Les méthodes de classification par clustering que nous venons de présenter ne prennent pas en compte l'interaction spatiale entre les pixels. Certains auteurs ont donc cherché à définir des méthodes de classification spatio-colorimétrique. BALASUBRAMANIAN ET AL. proposent dans [BALASU94], un algorithme de quantification d'images couleur basé sur le « variance-based-algorithm » et opérant dans un espace 3D. ORCHARD ET BOUMAN [ORCHAR91] proposent une classification de pixels qui minimise des écarts quadratiques inter-classes pondérés par un facteur tenant compte de l'interaction spatiale entre

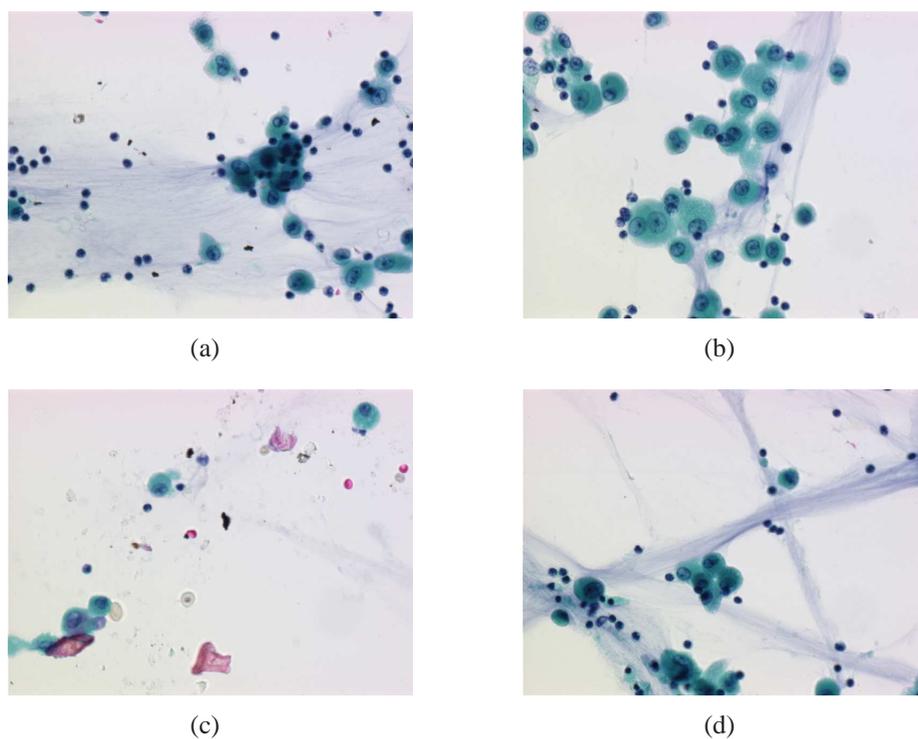


FIG. 3.12 – Quatre images d’une base d’apprentissage en imagerie microscopique biomédicale ((a) du mucus diffus et un groupement de cellules, (b) des cellules diverses, (c) une présence de globules rouges et des débris, (d) une forte concentration de mucus).

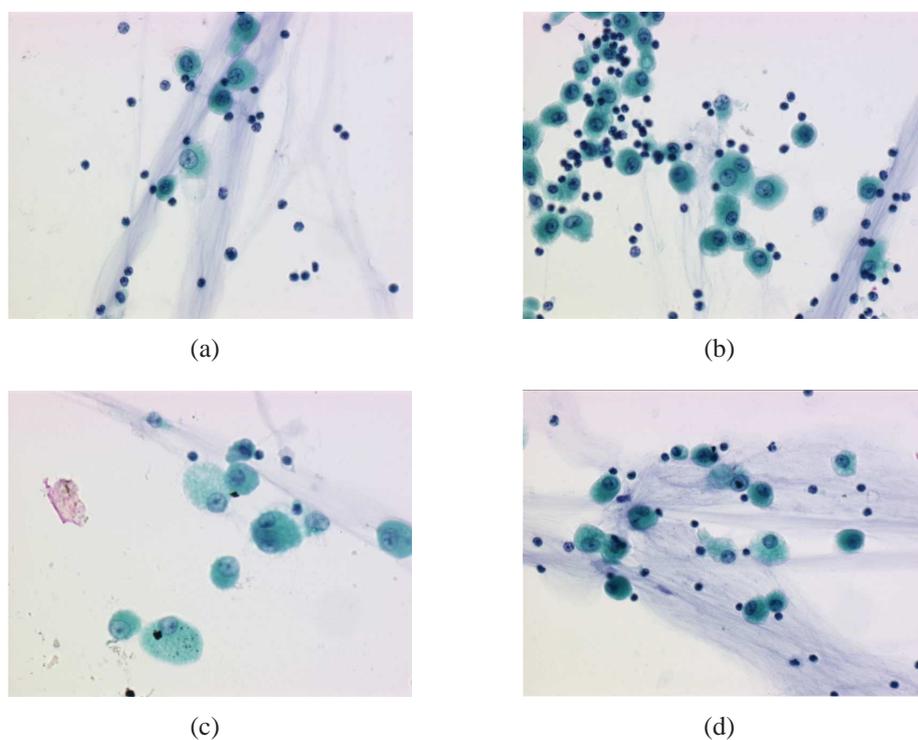


FIG. 3.13 – Quatre images d’une base de tests en imagerie microscopique biomédicale.

les pixels. L'idée consiste à pondérer les erreurs de classification en fonction d'un degré d'uniformité des différentes zones de l'image. Le lecteur pourra trouver s'il le désire de plus amples détails sur ces techniques dans les travaux de BALASUBRAMANIAN ET AL. [BALASU94], ORCHARD ET BOUMAN [ORCHAR91], PUZICHAT [PUZICH00], MACAIRE dans [MACAIR04] et FONTAINE [FONTAI04]. MACAIRE [MACAIR04] présente une stratégie qui consiste à sélectionner des domaines couleur de l'espace couleur qui définissent des sous ensembles couleur constitués de pixels fortement connexes dans l'image et ayant des couleurs les plus homogènes possible.

3.2 Construction de régions

Les méthodes de construction de régions que nous allons développer maintenant prennent en compte l'information spatiale des pixels dans l'image et traitent donc les pixels de façon spatio-colorimétrique. Ces méthodes se répartissent selon deux approches à savoir :

1. Les méthodes ascendantes regroupant les pixels par croissance de régions à partir de germes précédemment extraits ;
2. Les méthodes structurelles qui agissent directement sur une image de régions.

3.2.1 Méthodes ascendantes

Les méthodes ascendantes par croissance de régions proposées par plusieurs auteurs dont CHASSERY ET GARBAY [CHASSE84], ZUGAJ ET LATTUATI [ZUGAJ98], TRÉMEAU ET BOREL [TRÉMEA97] et MONGA [MONGA87] consistent à agréger aux régions, les pixels adjacents d'une image selon un certain critère de similarité. L'image est préalablement décomposée en plusieurs régions qui se trouvent ensuite regroupées de manière itérative selon un critère de similarité colorimétrique. La méthode de CHASSERY ET GARBAY [CHASSE84] pionnière dans ce domaine peut être décomposée en deux phases qui sont respectivement une phase d'initialisation et d'agrégation.

1. La première phase consiste à initialiser une région à partir d'un germe d'une zone de l'image non encore segmentée ;
2. La deuxième phase consiste en une opération de croissance où chaque pixel est agrégé à une région si le critère de similarité est inférieur à un seuil. L'auteur définit ici le critère de similarité comme une distance entre la couleur du pixel candidat et la couleur de référence de la région.

Des variantes de cette méthode ont été proposés par MOGHADDAMZADEH ET BOURKABIS [MOGHAD97], SHAFFARENKO ET PETROU [SHAFAR97] et par TRÉMEAU ET BOREL [TRÉMEA97] qui proposent d'autres critères de similarité colorimétriques prenant en compte l'information spatiale et colorimétrique. En voici une liste non-exhaustive :

- un critère de similarité local s'assurant que les couleurs respectives de deux pixels voisins d'une même région sont relativement proches ;
- un critère de similarité moyen vérifiant que la couleur d'un pixel ajouté à une région soit relativement proche de la couleur moyenne de ses voisins appartenant déjà à la région ;

- le nombre minimal de pixels voisins du pixel candidat et appartenant déjà à la région.

Le résultat d'une segmentation par croissance de régions dépend fortement du réglage des différents paramètres (sélection des germes, réglage des seuils, ordre de construction des régions et critère de similarité). Un mauvais choix de l'un d'entre eux peut entraîner des problèmes de sous ou de sur-segmentation. Mais en règle générale, ces méthodes fournissent de bons résultats sur l'extraction des régions homogènes de l'image mais s'avèrent moins performantes sur la qualité des contours.

Notons que des travaux dans le domaine de la morphologie mathématique basés sur des critères connectifs ont vu le jour et notamment ceux de CRESPO ET SCHAFER [CRESPO94] qui ont proposé une extension du concept de segmentation basée sur des zones plates et ceux de ZANOQUERA [ZANOQU01] proposant une définition vectorielle des zones quasi-plates. Des travaux plus récents comme ceux de GOMILA [GOMILA01] et LOPEZ [ANGULO03A] combinent l'usage des zones plates ou quasi-plates avec la Ligne de Partage des Eaux (LPE) calculée sur le gradient couleur. Nous informons le lecteur qu'une étude plus détaillée des ces approches morphologiques sera présentée dans le chapitre 6.

3.2.2 Méthodes structurelles

Les méthodes structurelles peuvent être classées en deux catégories que nous allons détaillées ci-dessous :

1. La division-fusion de régions reposant sur une structuration de l'image en régions faisant intervenir leur adjacences ;
2. La fusion de régions intervenant comme un post-traitement à l'étape de segmentation à la suite d'une sur-segmentation de l'image.

Nous détaillons ici succinctement ces méthodes sur lesquelles nous reviendrons en détail dans le chapitre 6.

3.2.2.1 Approche division-fusion de régions

En 1974, HOROWITZ ET PAVLIDIS [HOROWI74] ont proposé un algorithme de « division-fusion » (« split-and-merge » en anglais) pour des images en niveaux de gris, basé sur une structure arborescente appelée « tétra-arbre » (« quadtree » en anglais). Cet algorithme est décomposé en deux étapes :

1. Dans la première étape, chaque bloc (correspondant à un noeud du tétra-arbre) est analysé de sorte à savoir s'il doit être divisé en quatre sous blocs et ce jusqu'à ce que chaque sous-bloc respecte un prédicat d'homogénéité ;
2. Dans une deuxième étape, une fusion de blocs adjacents possédant des caractéristiques colorimétriques identiques est réalisée.

L'adaptation de cette technique aux images couleurs n'est pas sans poser quelques problèmes dans la définition du prédicat d'homogénéité. Les auteurs se consacrent alors à la définition de nouveaux algorithmes. COUTANCE [COUTAN91] propose dans une première étape de diviser un bloc en quatre sous blocs si la somme des variances des trois composantes R , G et B des pixels d'un bloc est supérieure à un seuil fixé et dans une deuxième

étape de fusionner les blocs adjacents si la distance entre les couleurs moyennes des pixels de chaque bloc est inférieure à un seuil fixé. L'inconvénient de cette approche basé sur un tétra-arbre réside dans le découpage de l'image. En effet le découpage carré ne permet toujours de prendre en compte la forme des régions de l'image. PANJWANI ET HEALEY [PANJWA95] proposent une approche de division-fusion basée sur les « champs de markov » prenant en compte les interactions spatiales et colorimétriques entre les pixels mais très coûteuse en temps de calcul.

3.2.2.2 Approche fusion de régions

Dans un cadre de la segmentation d'image, il n'est pas rare d'obtenir une image présentant un nombre de régions trop important au regard d'un problème donné. Ceci peut par exemple être du à l'utilisation de certaines méthodes de segmentation ou à une valeur de paramètre non adaptée. Une approche par fusion de régions peut alors être utilisée en post-traitement de l'étape de segmentation afin de réduire cette sur-segmentation de l'image. Les algorithmes de fusion de régions diffèrent les uns des autres par le critère de fusion, l'ordre de fusion et parfois le modèle de régions qu'ils utilisent. L'algorithme de SAARINEN [SAARIN94] par exemple, pondère chaque arête du graphe proportionnellement à la distance colorimétrique entre les deux régions et à chaque itération, les régions reliées par l'arête qui porte le poids minimal sont fusionnées. L'algorithme de TRÉMEAU ET COLANTONI [TRÉMEA00] utilise quant à lui trois critères spatio-colorimétriques de fusion que nous présentons ci-après et devant être impérativement respectés pour que deux régions adjacentes puissent être fusionnées.

- la distance colorimétrique entre la couleur moyenne des deux régions adjacentes doit être inférieure à un seuil fixé ;
- la distance colorimétrique entre la couleur d'une région et la couleur moyenne des régions adjacentes doit être inférieure à un seuil fixé. En d'autres mots, la région considérée ne doit pas être trop éloignée colorimétriquement de l'ensemble des régions qui lui sont adjacentes ;
- la région considérée doit être non seulement proche colorimétriquement de la région avec laquelle elle va fusionner mais également de toutes celles ayant déjà fusionné avec cette dernière.

Nous informons le lecteur qu'une étude plus détaillée des approches pyramidales sera présentée dans le chapitre 6.

3.2.3 Coopération régions-contours

Toujours dans un but de segmentation d'images couleur, plusieurs auteurs ont tenté de combiner différentes méthodes présentées dans ce chapitre en définissant des méthodes de coopération « régions-contours ». ZUGAJ ET LATTUATI proposent de faire coopérer une méthode de croissance de régions avec un gradient couleur calculé par la méthode de DiZenzo [DIZENZ86] afin de fermer les contours des objets en s'aidant de l'information régions. DIBOS ET KOEPFLER [DIBOS97] traite de la coopération d'une croissance de régions avec une méthode variationnelle. ZHU ET YUILLE [ZHU96] combinent les méthodes de croissance de régions avec celles des contours déformables (« snakes ») en uti-

lisant le formalisme du « Minimum Description Length » pour effectuer une déformation des régions en minimisant un certain critère. PHILIPP-FOLIGUET [PHILIP00] propose un algorithme de segmentation floue totalement automatique et ne nécessitant pas de germes de régions. Cette approche consiste à effectuer une croissance de régions floues à partir des pixels de plus faible gradient, en utilisant une distance topographique.

3.3 Conclusion

Nous avons passé en revue dans ce chapitre un certain nombre de méthodes de segmentation d'images couleurs. Certaines ont montré leur efficacité à extraire correctement les régions d'une image mais semblent moins efficaces dans la détection des contours. D'autres méthodes ont montré une importante difficulté dans le réglage de différents paramètres ou seuils comme des critères de similarité, des critères d'arrêt et ordre de fusion. Certaines méthodes sont plus adaptées à des post-traitement et produisent donc des sous ou sur-segmentation. Les méthodes de classification pixellaire quant à elles semblent de part la nature de nos images bien adaptées pour notre application. Nous avons donc choisi de présenter cette partie plus en détails en détaillant les principaux algorithmes de classification de pixels non-supervisée et supervisée que nous utiliserons dans le chapitre 5.

ÉVALUATION DE LA SEGMENTATION

Sommaire

4.1	Évaluation sans vérité terrain	49
4.2	Évaluation avec vérité terrain	52
4.3	Conclusion	61

DANS le domaine du traitement d'images, nous assistons à la multiplication des méthodes d'évaluation de segmentation d'images, qu'elles soit développées pour l'extraction de contours ou de régions, avec ou sans vérité terrain et que nous pouvons retrouver dans plusieurs travaux [DARUGN04, PHILIP01, LAUREN03, CHABRI04, CHABRI05, ZHANG96]. L'évaluation visuelle de résultats de segmentation est encore très présente notamment dans certains domaines d'application comme le domaine médical. Les inconvénients de ce type d'évaluation sont une mise en oeuvre particulièrement longue et fastidieuse et le besoin d'une intervention extérieure peut parfois nécessiter l'arrêt d'un processus de traitement jusqu'à validation de l'étape par l'être humain. Il devient alors crucial de pouvoir évaluer de façon totalement automatique et quantitative des résultats de segmentation pour permettre de comparer les performances de nouveaux algorithmes à ceux déjà existants mais également, de choisir un algorithme et de régler ses paramètres en fonction d'un problème donné.

Dans ce chapitre, nous présentons tout d'abord, un état de l'art des différentes méthodes d'évaluation existantes que nous séparons en deux catégories correspondant respectivement aux méthodes d'évaluation sans et avec vérité terrain. Puis nous proposons une nouvelle méthode d'évaluation spécialement adaptée aux attentes des experts du domaine de la cytologie et plus particulièrement à celui de la segmentation d'images microscopiques de tumeurs bronchiques.

4.1 Évaluation sans vérité terrain

De nombreux critères d'évaluation de segmentation sans vérité terrain ont été proposés dans la littérature. Ils fournissent une évaluation de la qualité d'une segmentation en se basant sur des statistiques calculées sur les régions comme la variation de couleur à l'intérieur des régions, de contraste entre les régions et de taille de régions. Ces critères ont l'avantage de ne pas nécessiter de vérité terrain ou de segmentation de référence, leur utilisation est justifiée dans des domaines d'application où la construction d'une base de vérité terrain est délicate ou trop coûteuse en temps. Nous présentons ci-dessous les cinq princi-

paux critères que nous retrouvons le plus souvent dans la littérature traitant de l'évaluation des méthodes de segmentation sans vérité terrain à savoir :

1. Critère d'uniformité intra-région de LEVINE ET NAZIF ;
2. Contraste inter-région de LEVINE ET NAZIF ;
3. Contraste de ZEBOU DJ ;
4. Mesure de dissimilarité de LIU ET YANG ;
5. Critère de BORSOTTI ET AL.

4.1.1 Critère d'uniformité intra-région de LEVINE ET NAZIF

Le critère d'uniformité intra-région LEVINE ET NAZIF [LEVINE85] que nous notons C_{LN}^{intra} est basé sur la somme des variances de régions et doit par conséquent être minimal.

$$C_{LN}^{intra} = \sum_i \frac{\sigma_i^2}{\sigma_{max}} = \sum_i \sum_{s \in R_i} \left(f(s) - \frac{1}{A_i} \sum_{s \in R_i} f(s) \right)^2 \quad (4.1)$$

où $f(s)$ est l'intensité du pixel s , A_i l'aire de la région R_i et σ_{max} un facteur de normalisation égal à $\frac{(f_{max}-f_{min})^2}{2}$.

4.1.2 Contraste inter-région de LEVINE ET NAZIF

Ce critère inter-région [LEVINE85] noté C_{LN}^{inter} calcule la somme des contrastes des régions R_i pondérée par leur aires A_i . Il est donné par l'équation suivante :

$$C_{LN}^{inter} = \frac{\sum_{R_i} A_i C_i}{\sum_{R_i} A_i} \quad (4.2)$$

où C_i représente le contraste de la région R_i et est donné par $C_i = \sum_{R_j} \frac{l_{ij}}{l_i} c_{ij}$ avec R_j qui représente les régions adjacentes à R_i , l_{ij} la longueur de la frontière commune entre R_i et R_j , l_i le périmètre de la région R_i , et C_{ij} le contraste entre 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.

4.1.3 Contraste de ZEBOU DJ

Ce critère noté C_Z prend en compte le contraste intérieur et extérieur aux régions mesurés sur un voisinage de chaque pixel [COCQUE95]. Le contraste intérieur $CInt_i$ et extérieur $CExt_i$ d'une région R_i sont donnés par les deux relations énoncées ci-après où $W(s)$ représente un voisinage du pixel s . A_i et l_i correspondent respectivement à l'aire et à la longueur de la frontière F_i de R_i . $c(s, t) = \frac{|f(s) - f(t)|}{L - 1}$ est le contraste entre deux pixels s et t avec f l'intensité et L le maximum des intensités :

$$CInt_i = \frac{1}{A_i} \sum_{s \in R_i} \max\{c(s, t), t \in W(s) \cap R_i\}$$

$$CExt_i = \frac{1}{A_i} \sum_{s \in F_i} \max\{c(s, t), t \in W(s) \notin R_i\}$$

Le contraste de R_i est défini par :

$$C(R_i) = \begin{cases} 1 - \frac{CInt_i}{CExt_i} & \text{si } 0 < CInt_i < CExt_i \\ CExt_i & \text{si } CInt_i = 0 \\ 0 & \text{sinon} \end{cases}$$

Le contraste global de ZEBOUJ C_Z est alors donné par la relation suivante :

$$C_Z = \frac{1}{A} \sum_i A_i \times C(R_i) \quad (4.3)$$

Notons que cette méthode proposée par ZEBOUJ semble ne pas être adaptée aux images texturées comme cela est montré dans les travaux de ZHANG [ZHANG96].

4.1.4 Mesure de dissimilarité de LIU ET YANG

La mesure de dissimilarité de LIU ET YANG [LIU94] notée C_{LY} devant être faible, intègre trois paramètres qui sont le nombre de régions, l'aire des régions et la couleur moyenne de chaque région. Cette mesure pénalise les segmentations ayant un nombre de régions trop importants ou ayant des régions non homogènes en couleur.

$$C_{LY} = \frac{1}{1000 \times A} \sqrt{N} \sum_{i=1}^N \frac{e_i^2}{\sqrt{A_i}} \quad (4.4)$$

où A_i est le nombre de pixels de la région R_i et A le nombre total de pixels de l'image $A = \sum A_i$. N représente le nombre de régions de l'image segmentée. e_i^2 correspond à l'erreur quadratique portant sur la couleur de la région R_i . Elle est calculée à partir de la somme des distances de norme L_2 entre les vecteurs couleur des pixels de la région R_i et le vecteur couleur attribué à la région R_i dans l'image segmentée égal en général à la moyenne des couleurs de la région.

4.1.5 Critère de BORSOTTI ET AL

Le critère de Borsotti et al. [BORSOT98] noté C_B est une amélioration de la mesure de LIU ET YANG présentée ci-dessus qui avait pour inconvénient de pénaliser les segmentations ayant un nombre de régions trop importants ou ayant des régions non homogènes en couleur. Ce critère est basé sur les mêmes paramètres que précédemment (le nombre de régions, l'aire des régions et la couleur moyenne de chaque région) mais voit sa formulation améliorée :

$$C_B = \frac{1}{10000 \times A} \sqrt{N} \sum_{i=1}^N \left[\frac{e_i^2}{1 + \log A_i} + \frac{R(A_i)^2}{A_i^2} \right] \quad (4.5)$$

avec A_i le nombre de pixels de la région R_i et A le nombre total de pixels de l'image. N représente le nombre de régions de l'image segmentée. $R(A_i)$ est le nombre de régions ayant une aire égale à A_i . e_i^2 correspond à l'erreur quadratique portant sur la couleur de la région R_i et calculée de la même façon que dans la mesure de dissimilarité de LIU ET YANG. La particularité intervient dans les deux termes suivant : le terme $\frac{e_i^2}{1 + \log A_i}$ favorise les régions homogènes tandis que le terme $\frac{R(A_i)^2}{A_i^2}$ pénalise les images sur-segmentées ayant beaucoup de régions de tailles similaires.

4.2 Évaluation avec vérité terrain

Nous allons maintenant présenter quatre méthodes d'évaluation avec vérité terrain pour la segmentation d'images couleur par approche région. Ces méthodes sont basées sur une mesure de similarité entre l'image segmentée et sa vérité terrain. Notons que la dernière méthode d'évaluation citée ci-dessous est proposée pour une application spécifique qui est l'évaluation de segmentations d'images microscopiques de cytologie bronchique :

1. Mesure de MARTIN ;
2. Mesure de YASNOFF ET AL ;
3. Mesure de VINET ET AL ;
4. Méthode adaptée à la microscopie.

4.2.1 La vérité terrain

La littérature n'abonde pas de méthode d'évaluation nécessitant une vérité terrain. Le problème principal rencontré dans ce type d'évaluation consiste en l'obtention d'une segmentation de référence ou d'une vérité terrain. Cette remarque est d'autant plus valable pour la recherche appliquée puisqu'il est parfois difficile d'obtenir un nombre suffisant d'images pour constituer une base de référence du fait dans certains cas de la nature de ces images. Mais ceci n'est pas la seule cause, d'autres facteurs rendent l'utilisation de ces méthodes peu utilisées. Nous citons ici trois de ces facteurs en s'appuyant sur les résultats d'une segmentation de référence d'une image de la base de Berkeley [BERKEL] (produite par différents experts) ainsi que sur l'expérience d'experts du domaine biomédical.

1. Le problème de concordance entre les experts reste un problème de taille puisqu'il n'est pas rare de voir certaines différences de segmentation très nettes pour une même image. Nous illustrons ce point sur la figure 4.1 en montrant plusieurs segmentations de référence réalisées par différents experts et ce pour une même image. Pour plus de clarté, nous avons préféré ne pas présenter l'illustration sur des images

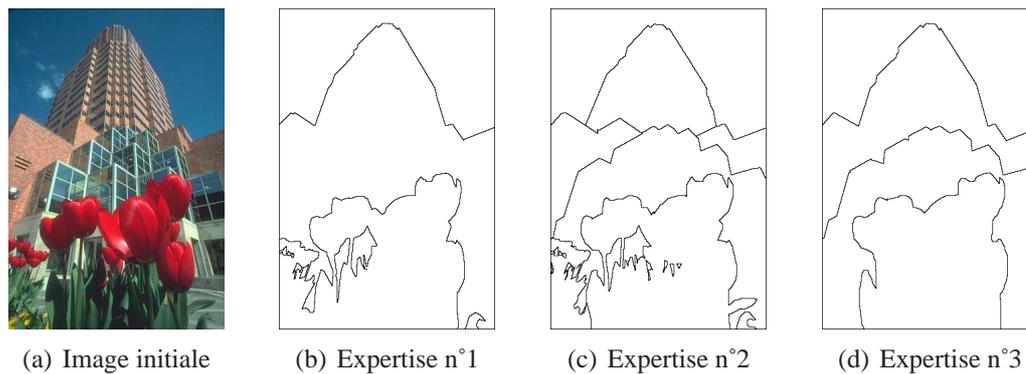


FIG. 4.1 – Concordance entre plusieurs segmentations de référence produites par différents experts.

microscopiques (à cause du nombre important et de la faible taille des objets) mais sur une image de la « *Berkeley Segmentation Dataset and Benchmark* ».

Dans le cadre d'une application spécifique telle que la détection de cellules anormales dans des images microscopiques de tumeurs bronchiques, l'évaluation de la qualité de la segmentation doit permettre d'assurer une sécurisation du diagnostic. Nous comprendrons alors que la construction d'une base de référence demande une grande précision pouvant engendrer différents problèmes comme ceux énoncés ci dessous ;

2. Il est parfois difficile pour l'expert de délimiter précisément les contours de certaines régions (à cause de la présence de flou lors de l'acquisition, de bruit, de débordement de coloration dans le cadre de la microscopie cellulaire) ;
3. Le temps passé par un expert du domaine à segmenter une image. Notons que dans le cadre de segmentation d'images microscopiques cellulaires, les experts du domaine avec lesquels nous avons travaillé s'imposent une précision à deux pixels, ce qui rend le temps de réalisation d'une seule image de référence exorbitant.

Comme nous venons de l'introduire, la construction d'une vérité terrain fait appel aux compétences d'un expert du domaine de l'image à traiter. Dans le cadre d'images microscopiques de tumeurs bronchiques, nous utilisons les compétences d'un expert en cytopathologie qui sera le plus à même d'effectuer une segmentation que nous qualifierons de référence où les objets qui lui sembleront intéressants seront extraits. La figure 4.2 présente les principales étapes de la construction d'une segmentation de référence. Nous partons d'une image acquise dans des conditions particulières strictes qui permettent de se retrouver dans des conditions d'acquisition identiques pour chaque prise d'image [CAILLO05] :

- la température de la couleur doit être de $5500 \text{ K} \cong 9\text{V}$ et donc contrôlée par un voltmètre ;
- le réglage du diaphragme est effectué par rapport à une mire de calibration des densités optiques ;
- l'acquisition des images doit se faire dans le noir ;
- l'ensemble d'acquisition (microscope et caméra) doit avoir une stabilisation thermique d'1H30.

L'expert en cytopathologie utilise ensuite un logiciel de dessin et définit à l'aide de la souris les contours de chaque objet qu'il juge intéressant d'extraire (typiquement pour cette application, les contours dessinés représentent ceux des objets cytoplasmiques et nucléaires). Il est à noter que tous les objets présents dans une image ne sont pas forcément segmentés par l'expert si ceux-ci ne sont d'aucun intérêt pour l'application concernée (mucus, débris, hématies, etc). Il convient ensuite de remplir d'une couleur différente pour chaque type d'objet, la région délimitée par son contour. Afin de disposer d'une image de référence complète, il suffit ensuite de superposer sur une même image, l'image correspondant aux objets cytoplasmiques et celle correspondant aux objets nucléaires. La figure 4.3 illustre quatre segmentations de référence d'une base d'apprentissage.

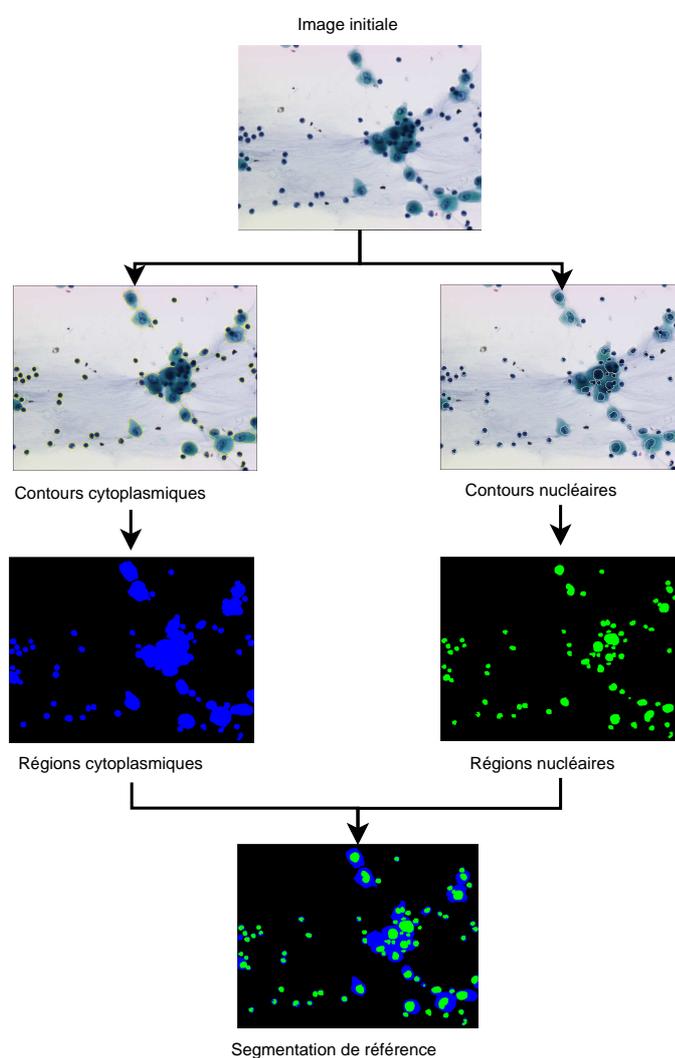


FIG. 4.2 – Création d'une segmentation de référence pour une image cytopathologique.

Nous rappelons maintenant les quatre méthodes que nous retrouvons le plus souvent dans les travaux traitant de l'évaluation des méthodes de segmentation avec vérité terrain.

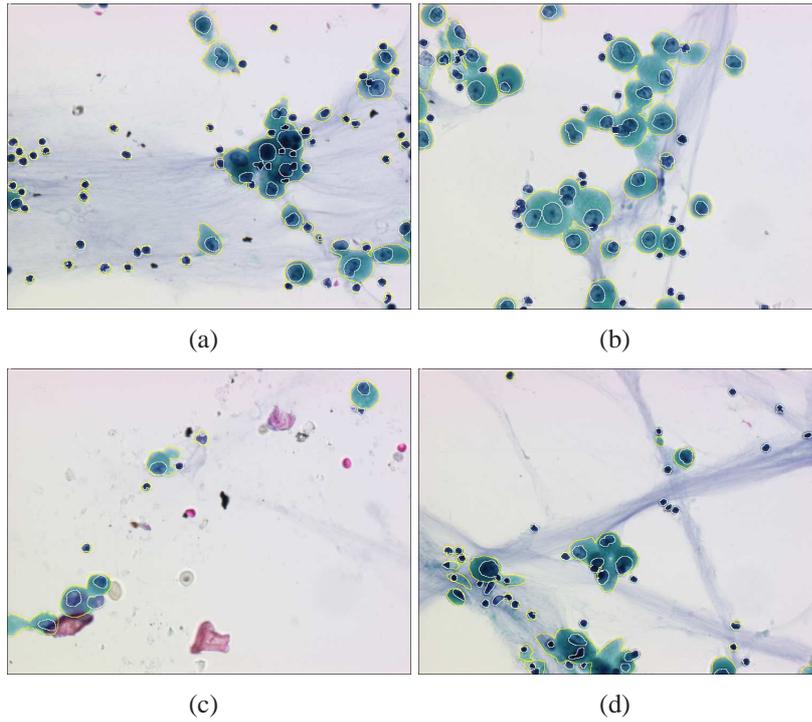


FIG. 4.3 – Quatre segmentations de référence d'une base d'apprentissage.

4.2.2 Mesure de MARTIN

La mesure de MARTIN [MARTIN02] mesure la cohérence entre deux segmentations en se basant sur l'erreur calculée en chaque pixel mesurée soit par l'erreur locale de cohérence soit par l'erreur globale de cohérence :

$$LCE(I, V) = \frac{1}{A} \sum_s \min \{ (E(s), E'(s)) \} \quad (4.6)$$

$$CGE(I, V) = \frac{1}{A} \min \{ \sum_s E(s), \sum_s E'(s) \} \quad (4.7)$$

avec

$$E(s) = \frac{\text{card}(V_j/R_i)}{\text{card}(V_j)}$$

$$E'(s) = \frac{\text{card}(R_i/V_j)}{\text{card}(R_i)}$$

$$E(s) = \begin{cases} 0 & \text{si } V_j \in R_i \\ 0 & \text{sinon} \end{cases}$$

où s est le pixel appartenant à la région V_j dans l'image de référence et à la région R_i dans l'image segmentée.

4.2.3 Mesure de YASNOFF ET AL

La mesure proposée par YASNOFF ET AL notée C_Y , consiste à compter le nombre de pixels mal segmentés tout en tenant compte de leur position [ZHANG96] :

$$C_Y = \frac{100}{A} \sqrt{\sum_{s \in s_T} d^2(s, s_r)} \quad (4.8)$$

où A représente le nombre total de pixels dans l'image, s_T le nombre total de pixels mal segmentés et d la distance entre le pixel mal classé s et le pixel s_r le plus proche de la région à laquelle il appartient dans l'image de référence.

4.2.4 Mesure de VINET

La mesure de VINET [COHEN89] que nous noterons C_V 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 est caractérisée par la proportion de pixels ne participant pas au recouvrement des couples de régions. La première étape consiste à définir une table de partition notée T et définie comme suit :

$$T(i, j) = \text{card}(R_i \cap V_j) \quad (4.9)$$

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 $C_1 = T(i_1, j_1)$ représente le couple (R_{i_1}, V_{j_1}) de recouvrement maximal tel que :

$$T(i_1, j_1) \geq T(i, j) \quad \forall i, j \quad (4.10)$$

La recherche du second maximum noté $C_2 = T(i_2, j_2)$ donne le couple (R_{i_2}, V_{j_2}) tel que :

$$T(i_2, j_2) \geq T(i, j) \quad \forall i, j \quad (4.11)$$

On réitère cette opération jusqu'au couple C_K avec $K = \min(m, n)$ le nombre de couples de régions (R_{i_k}, V_{j_k}) . La mesure de dissimilarité doit être faible et est donnée par :

$$1 - \frac{1}{A} \times \sum_{k=1}^K C_k \quad (4.12)$$

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

4.2.5 Une méthode d'évaluation adaptée à la cytologie

La méthode d'évaluation que nous allons définir ci-dessous a été développée pour une application en microscopie cellulaire [MEURIE03A, MEURIE03B, MEURIE03C]. L'utilisation d'images microscopiques et notamment de cytologie bronchique requiert un critère d'évaluation adapté à la nature des images à traiter et donc plus performant que ceux précités (BORSOTTI ou de VINET). Dans un système d'aide à la décision, la méthode d'évaluation des résultats est capitale pour établir un diagnostic. Il convient donc d'utiliser une méthode prenant en compte un objet qui n'aurait pas été segmenté alors qu'il se trouvait être important ou encore incluant pour chaque type d'objet, le nombre de pixels correctement identifiés ou non. MEAS-YEDID [MEAS-Y04] a proposé une méthode pour choisir le meilleur espace couleur pour la segmentation d'images microscopiques. Dans cet article [MEAS-Y04], deux critères de BORSOTTI ET AL. modifiés sont proposés et adaptés à différentes applications biologiques. En pénalisant l'inhomogénéité, les petites régions et les régions mal classifiées, le critère permet d'aider à la sélection du meilleur espace pour une application donnée. Cependant ce critère n'est pas réellement adapté aux problématiques spécifiques à la microscopie car il ne tient pas compte de la disparition d'objets importants. La méthode d'évaluation que nous proposons, adaptée à la microscopie cellulaire emploie une segmentation de référence et est basée sur un taux de classification amélioré initialement proposé par SCHÜPP [SCHUPP01].

La méthode proposée fournit un indice de qualité sur la reconnaissance du cytoplasme « $Indice_{cytoplasme}$ » et du noyau « $Indice_{noyau}$ ». Pour calculer ces indices, nous calculons le nombre de pixels appartenant à chaque classe de l'image. Le taux de commun « $Com_{cytoplasme}$ » ou « Com_{noyau} » montre le nombre de pixels correctement identifiés dans l'image de référence. Tandis que le taux de différence « $Diff_{cytoplasme}$ » ou « $Diff_{noyau}$ » globalise pour une classe C donnée (cytoplasme ou noyau), les deux erreurs suivantes :

1. Un pixel de la classe C dans l'image de référence n'est pas reconnu comme étant de la même classe dans l'image segmentée ;
2. Un pixel n'étant pas de la classe C dans l'image segmentée est reconnu comme étant de la classe C dans l'image de référence.

Cette méthode d'évaluation peut alors être définie par les équations suivantes :

$$Indice_{cytoplasme} = \frac{Com_{cytoplasme} + (1 - Diff_{cytoplasme})}{2} \quad (4.13)$$

$$Indice_{noyau} = \frac{Com_{noyau} + (1 - Diff_{noyau})}{2} \quad (4.14)$$

Les équations (4.13) et (4.14) fournissent respectivement l'indice de qualité sur la reconnaissance du cytoplasme et du noyau, en prenant en compte le nombre de pixels bien classés (1er terme : « Com_{noyau} ») et le nombre de pixels mal classés (2ème terme : « $1 - Diff_{noyau}$ »).

Posons $E_{\alpha}^{\beta} = \{(x, y) \in I | I_{\beta}(x, y) = \alpha\}$ où F représente le « fond », C le « cytoplasme », N le « noyau », R l'image de référence, S l'image segmentée.

$$Com_{cytoplasme} = \frac{|E_{\{C\}}^R \cap E_{\{C\}}^S|}{|E_{\{C\}}^R|} \quad (4.15)$$

$$Com_{noyau} = \frac{|E_{\{N\}}^R \cap E_{\{N\}}^S|}{|E_{\{N\}}^R|} \quad (4.16)$$

Dans les équations (4.15) et (4.16), nous calculons respectivement pour le cytoplasme et pour le noyau, le nombre de pixels correctement identifiés. Cela revient alors pour « Com_{noyau} », à faire l'intersection entre le nombre de pixels étiquetés « *noyau* » dans l'image de référence et étant effectivement étiquetés « *noyau* » dans l'image segmentée, et de normaliser ensuite le tout en divisant ce résultat par le nombre de pixels étiquetés « *noyau* » dans l'image de référence. La méthode est identique en ce qui concerne le calcul relatif au cytoplasme.

$$Dif_{cytoplasme} = \frac{|(E_{\{C\}}^R \cap E_{\{F\}}^S) \cup (E_{\{F\}}^R \cap E_{\{C\}}^S)|}{|E_{\{C\}}^R \cup E_{\{C\}}^S|} \quad (4.17)$$

$$Dif_{noyau} = \frac{|(E_{\{N\}}^R \cap E_{\{F,C\}}^S) \cup (E_{\{F,C\}}^R \cap E_{\{N\}}^S)|}{|E_{\{N\}}^R \cup E_{\{N\}}^S|} \quad (4.18)$$

Dans l'équation (4.17), nous nous intéressons aux pixels cytoplasmiques mal identifiés. Pour cela, nous effectuons une intersection entre les pixels étiquetés « *cytoplasme* » dans l'image de référence et qui correspondent à des pixels étiquetés « *fond* » dans l'image segmentée et les pixels étiquetés « *fond* » dans l'image de référence et qui correspondent à des pixels étiquetés « *cytoplasme* » dans l'image segmentée. Nous normalisons ensuite ce résultat en le divisant par le nombre de pixels étiquetés « *cytoplasme* » dans l'image de référence et segmentée.

Dans l'équation (4.18), nous nous intéressons aux pixels nucléaires mal identifiés. Pour cela, nous effectuons une intersection entre les pixels étiquetés « *noyau* » dans l'image de référence et qui correspondent à des pixels étiquetés « *fond* » ou « *cytoplasme* » dans l'image segmentée et les pixels étiquetés « *fond* » ou « *cytoplasme* » dans l'image de référence et qui correspondent à des pixels étiquetés « *noyau* » dans l'image segmentée. Nous normalisons ensuite ce résultat en le divisant par le nombre de pixels étiquetés « *noyau* » dans l'image de référence et segmentée.

Il est important de signaler que les indices de qualité sur la reconnaissance des objets cellulaires (i.e. le cytoplasme et le noyau) calculés par cette méthode doivent être considérés à leurs justes valeurs. En effet, les indices sont calculés sur la base du pixel lui-même et une erreur de reconnaissance d'un pixel sur chaque objet entraîne une diminution en pourcentage de l'indice en question. Notons que l'indice de qualité présenté n'est pas un pourcentage, mais pour plus de lisibilité, nous le noterons comme tel. En cytologie

bronchique par exemple, il est très difficile voire impossible pour les experts de délimiter précisément à moins de deux pixels près le contour des objets. Ce qui revient à dire que toute classification pixellaire ou segmentation produite est considérée comme très correcte à plus ou moins deux pixels sur chaque objet. En conséquence de quoi, les indices approchant les 80 % peuvent être considérés comme représentant une bonne qualité de segmentation. Notons également que dans ce cadre applicatif, les experts du domaine souhaitent donner plus d'importance aux objets nucléaires (apportant plus d'information sur la malignité d'une cellule) qu'aux objets cytoplasmiques. Nous avons défini qu'une segmentation S_2 est meilleure qu'une segmentation S_1 si $(Indice_{noyau}(S_2) > Indice_{noyau}(S_1))$ pour $(Indice_{noyau}(S_2) - Indice_{noyau}(S_1)) \geq seuil$, sinon nous comparons $Indice_{cytoplasme}$. La valeur de ce seuil a été déterminée en accord avec les experts du domaine comme étant égale à 1.

Le tableau 4.1 présente les résultats de trois méthodes d'évaluation (BORSOTTI ET AL., VINET qui se trouvent être les plus couramment utilisées dans la littérature, et la nouvelle méthode d'évaluation adaptée à la microscopie que nous proposons) pour une segmentation par l'algorithme de Bayes, des images cytologique d'une base de tests (contenant des centaines d'objets cellulaires) dans trois espaces de représentation couleur que nous avons choisi arbitrairement à savoir (YCh_1Ch_2 , YUV , RGB).

La méthode d'évaluation que nous proposons permet de dissocier l'indice de qualité sur la reconnaissance du cytoplasme par rapport à celui du noyau, ce qui peut s'avérer avantageux lorsque l'on souhaite comme c'est le cas ici privilégier un indice par rapport à un autre. Le différentiel existant entre les différents résultats utilisant cette méthode d'évaluation en fonction de l'espace de représentation couleur choisi est plus important que celui donné par la méthode de BORSOTTI ET AL. ou de VINET, ce qui permet alors de s'assurer de la meilleure qualité d'une segmentation par rapport à une autre.

Espace	Liu	Vinet	$Indice_{cytoplasme}$	$Indice_{noyau}$
YCh_1Ch_2	6.2	45.1	71.1 %	76.7 %
YUV	6.3	45.2	63.8 %	76.7 %
RGB	6.1	45	72.2 %	73.3 %

TAB. 4.1 – Résultats de différentes évaluations sur la segmentation de la base de tests par l'algorithme de Bayes.

La figure 4.4 et le tableau 4.2 illustre le résultat de trois méthodes d'évaluation sur une image de la base de tests segmentée par l'algorithme de Bayes. Nous constatons que des objets nucléaires (noyaux) présents sur la figure 4.4(c) ont disparus sur la figure 4.4(d). Or les résultats de l'évaluation fournis par les méthodes de BORSOTTI ET AL. et VINET ne laissent pas transparaître ce changement. La méthode d'évaluation que nous proposons montre ce changement par une forte diminution de l'indice de reconnaissance du noyau. Nous considérons donc que la méthode que nous proposons est réellement adaptée à cette application et fournit des résultats de meilleures qualités que ceux fournis par les méthodes de BORSOTTI ET AL. ou de VINET. C'est pourquoi, nous utiliserons dans la suite de ce manuscrit cette méthode pour illustrer nos résultats applicatifs.

Image	Liu-Borsotti	Vinet	$Indice_{cytoplasme}$	$Indice_{noyau}$
Image 4.4(c)	9.4	51	74.8 %	84.4 %
Image 4.4(d)	9.8	51.8	72.2 %	73.3 %

TAB. 4.2 – Résultats de trois méthodes d'évaluation sur une image segmentée.

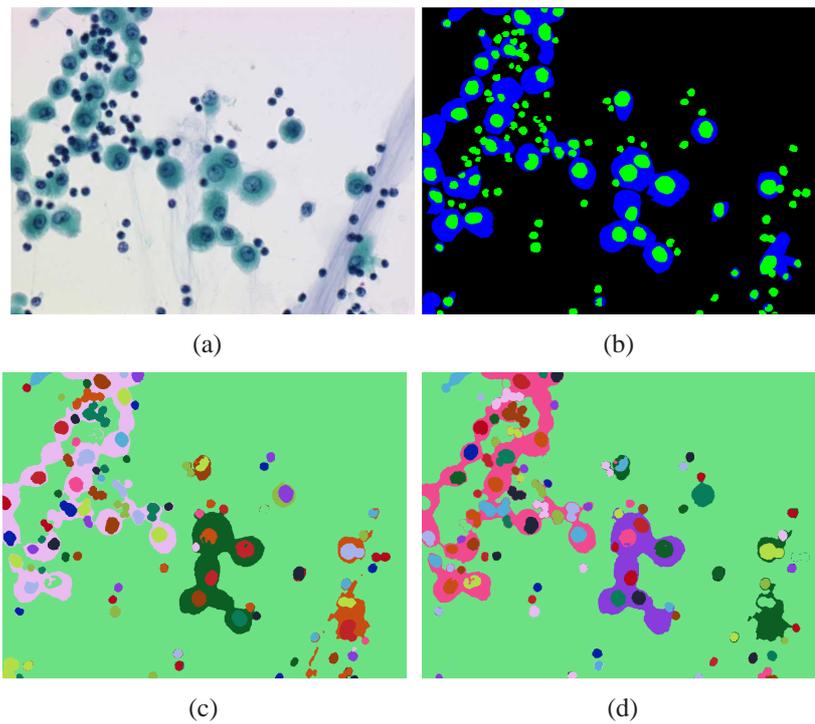


FIG. 4.4 – Résultats de différentes évaluations sur la segmentation d'une image par l'algorithme de Bayes ((a) l'image initiale, (b) la vérité terrain, (c-d) deux images segmentées.)

4.3 Conclusion

Nous avons dans ce chapitre présenté les principales méthodes d'évaluation de segmentation d'images couleur, qu'elles nécessitent ou non l'emploi d'une segmentation de référence. Certaines de ces méthodes ont été identifiées comme non adaptées à l'évaluation d'images texturées. D'autres ont été présentées comme pénalisant les segmentations ayant un nombre de régions trop important ou des régions non homogènes en couleur. Nous avons également présenté les problèmes liés à la création d'une vérité terrain ou d'une segmentation de référence, faisant que les méthodes nécessitant celles-ci sont peu utilisées. Nous avons terminé ce chapitre en présentant une nouvelle méthode d'évaluation pour des images microscopiques de cytologie bronchique définie en accord avec les attentes des experts. Des illustrations ont été présentées afin de montrer la supériorité de cette nouvelle méthode par rapport à d'autres existantes. Il va de soi que nous utiliserons, dans la suite de ce manuscrit, cette méthode d'évaluation pour illustrer nos résultats applicatifs.

UNE APPROCHE HYBRIDE DE SEGMENTATION D'IMAGES COULEUR

Sommaire

5.1	Simplification de l'image	63
5.2	Classification pixellaire non supervisée	64
5.3	Classification de pixels supervisée	75
5.4	Combinaison de classifications pixellaires	79
5.5	Intégration dans une approche morphologique	87
5.6	Conclusion	92

DANS ce chapitre, nous allons présenter une approche hybride de segmentation d'images couleur. Nous illustrerons nos résultats sur des images microscopiques de cytologie bronchique. Dans un premier temps, nous nous attacherons à classer les différents d'objets d'une image. Pour ce faire, nous présenterons deux approches qui sont la classification de pixels non supervisée et supervisée. Pour ce premier type de classification, nous proposerons deux approches que nous nommerons « classification pixellaire en une étape » et « classification pixellaire en deux étapes ». Cette dernière utilise un masque de l'image de sorte à classer plus précisément certains pixels d'un même type d'objets. L'utilisation combinée de plusieurs classifications pixellaires entraînant des conflits d'affectation de classes, nous proposerons ensuite une méthode de combinaison de classifications pixellaires basée sur des méthodes existantes mais avec la particularité de tenir compte de l'information de voisinage et du nombre de classifieurs combinés. Dans un deuxième temps, nous montrerons que cette approche de classification pixellaire peut aussi s'intégrer parfaitement dans une stratégie de segmentation d'images couleur par morphologie mathématique.

5.1 Simplification de l'image

Une étape de simplification de l'image initiale couleur I_0 , basée sur une augmentation du contraste global et la réduction du bruit est réalisée avant tout autre traitement sur l'image. L'image simplifiée I peut ensuite être utilisée en entrée de l'étape de classification de pixel afin de diminuer la sensibilité du classifieur à la présence de bruit. Pour simplifier cette image, nous utilisons une technique proposée par TSCHUMPERLÉ dans [TSCHUM01] basée sur les Équations aux Dérivées Partielles (EDP) et définie ci-dessous :

$$\frac{\partial I}{\partial t} = \alpha_d(g(\sqrt{\lambda_+})I_{\eta\eta} + I_{\xi\xi}) + \alpha_a(I - I_0) - \alpha_c(1 - g(\sqrt{\lambda_+}))U \quad (5.1)$$

avec

$$U = \begin{pmatrix} \text{sign}(I_{\eta\eta}^1) \|(I_{\eta}^1)\| \\ \vdots \\ \text{sign}(I_{\eta\eta}^n) \|(I_{\eta}^n)\| \end{pmatrix} \quad (5.2)$$

Les paramètres α_a , α_c et α_d fixés par l'utilisateur montrent l'importance de l'attache aux données, du filtre de choc et de la diffusion. $\sqrt{\lambda_+}$ caractérise la norme du gradient couleur, η et ξ ses directions. Le gradient couleur est obtenu par la méthode de DIZENZO [DIZENZ86]. La fonction $g(\cdot)$ est une fonction décroissante définie comme suit :

$$g(s) = \exp\left(-\frac{s^2}{2r^2}\right) \quad (5.3)$$

Cette fonction est composée de trois termes caractérisant respectivement, l'attache aux données, un filtre de choc et la diffusion, que nous détaillons ci-dessous.

1. Le terme $\alpha_a(I - I_0)$ correspond à un critère appelé « attache aux données » et est employé afin que l'image finale calculée soit proche de l'image initiale ;
2. Le terme $\alpha_c(1 - g(\sqrt{\lambda_+}))U$ appelé « filtre de choc » permet de rehausser le contour dans la direction du gradient (calculé par la méthode de DIZENZO [DIZENZ86]) afin de réduire le flou présent dans l'image. Ceci revient alors à rehausser chaque composante dans une direction commune η . Néanmoins, pour éviter le rehaussement dans les zones homogènes, on effectue une pondération par la fonction $(1 - g(s))$;
3. Le terme $\alpha_d(g(\sqrt{\lambda_+})I_{\eta\eta} + I_{\xi\xi})$ caractérise « l'importance de la diffusion ». Dans les zones homogènes ($g \cong 1$), la diffusion est isotropique et sur les contours ($g \cong 0$), la diffusion est parallèle à ces derniers ce qui permet de les préserver.

La figure 5.1 illustre une image microscopique de cytologie bronchique simplifiée par cette méthode.

5.2 Classification pixellaire non supervisée

La simplification de l'image étant effectuée, nous allons à présent chercher à classer les différents objets de l'image. Pour ce faire, nous avons choisi d'utiliser une approche par classification pixellaire. Cependant les images sur lesquelles nous travaillons présentent des objets inclus l'un dans l'autre (pour une cellule, un objet nucléaire sera dans la plupart des cas inclus dans un objet cytoplasmique) rendant une simple classification pixellaire délicate. Nous avons proposés donc deux approches différentes de classification pixellaire nommées respectivement, « classification pixellaire en une étape » et « classification pixellaire en deux étapes » permettant de traiter ce problème, que nous présentons en détail ci-après [MEURIE02, MEURIE03D].

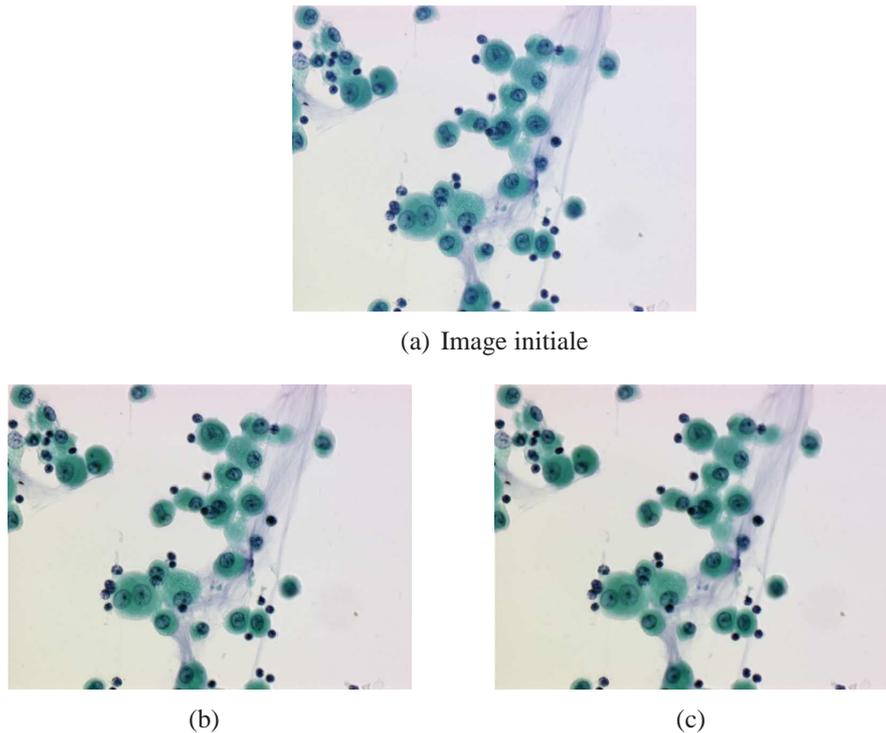


FIG. 5.1 – Exemple de simplification d’image : ((a) une image de la base de tests, (b) image simplifiée avec l’attache aux données, (c) image simplifiée avec l’attache aux données, la diffusion et la réaction).

Dans la suite de ce manuscrit, nous n’utiliserons que les classifieurs des k -moyennes et de Fisher sur les trois classifieurs non supervisés que nous avons présentés dans le chapitre 3 car les temps de calculs pour l’algorithme des C -moyennes floues sont prohibitifs. Nous tenons aussi à informer le lecteur que nous utiliserons pour une meilleure lisibilité, une notation spécifique pour tous les tableaux de ce chapitre. Les premières lettres correspondent à l’objet que l’on souhaite classer (le cytoplasme ou le noyau). Le chiffre et la lettre qui suivent indiquent le nombre de classes (« $3c$ » pour trois classes). Il faut donc lire par exemple pour « *Cytoplasme $3c$* » une classification du cytoplasme avec un classifieur discriminant trois classes, certaines étant fusionnées par la suite.

5.2.1 Classification pixellaire non supervisée en une étape

La classification pixellaire en une étape, comme présentée sur la figure 5.2, peut être résumée par une simple classification de pixels mais avec deux particularités :

1. La première particularité consiste à effectuer plusieurs classifications de pixels en parallèle, correspondant au nombre d’objets différents que l’on souhaite classer ;
2. La deuxième particularité consiste à prendre un nombre de classes k supérieur au nombre d’objets que l’on souhaite voir classer et d’effectuer ensuite une fusion par classification ascendante hiérarchique (CAH) entre certaines de ces classes pour obtenir la classe désirée. Cette fusion s’effectue selon un critère de distance caractérisé par la distance de la couleur moyenne de chaque classe par rapport au noir (car les couleurs sont proches de l’axe de luminance). Notons aussi qu’une connaissance

même minime sur les images à traiter apporte un avantage certain dans le choix de ces paramètres.

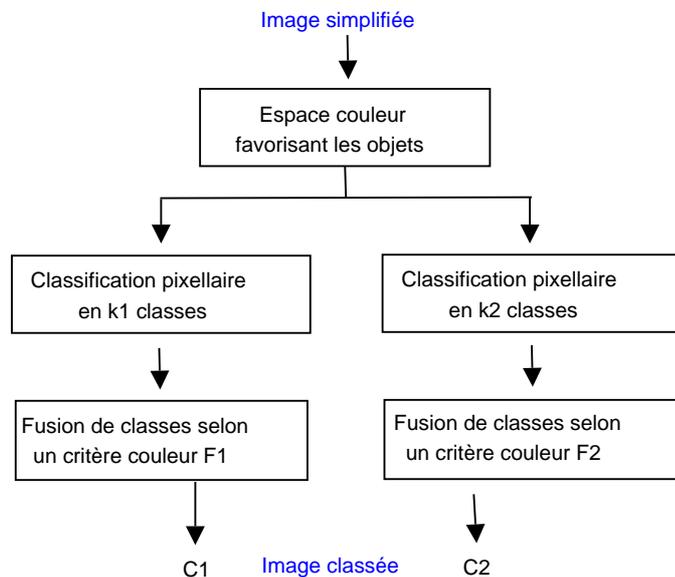


FIG. 5.2 – Principe de la classification pixellaire en une étape.

Dans le cadre d'images microscopiques de tumeurs bronchiques, l'utilisation de l'approche de « classification pixellaire en une étape » revient à effectuer deux classifications pixellaires en parallèle, l'une pour les cytoplasmes et l'autre pour les noyaux. Prenons l'exemple de la classification du cytoplasme. L'étape de classification de pixels doit être constituée d'au moins trois classes correspondant à trois types d'objets (le fond, le mucus, le cytoplasme). Mais nous verrons dans les tableaux présentés ci-après, qu'il peut être intéressant d'augmenter la valeur de ce paramètre de sorte à obtenir un nombre de classes plus important (par exemple : les nucléoles, le noyau, le cytoplasme, la membrane cytoplasmique, le mucus et le fond) et de fusionner ensuite certaines classes entre elles par une classification ascendante hiérarchique selon un critère de distance pour obtenir la classe désirée. Pour ce faire, nous devons au préalable trier chaque classe par rapport à la distance entre sa couleur moyenne et le noir. Pour illustrer cette fusion, prenons l'exemple d'une classification pixellaire en quatre classes où la classe C_1 représente le noyau, C_2 le cytoplasme, C_3 le mucus et C_4 le fond. Notons que le noyau étant plus sombre donc plus proche du noir que le cytoplasme, nous avons $C_1 > C_2$ et si nous poursuivons la logique, nous définissons l'ordre suivant : $C_1 > C_2 > C_3 > C_4$. Pour obtenir la classification du noyau, nous effectuons une fusion de classes selon un critère de distance couleur par rapport au blanc. Nous fusionnons alors les classes C_2 , C_3 et C_4 ensemble (qui représenteront le fond) et gardons intacte la classe C_1 (qui représentera le noyau). Pour la classification du cytoplasme, nous effectuons une fusion de classes selon un critère de distance couleur par rapport au noir i.e nous fusionnons les classes C_1 , C_2 (qui représenteront le cytoplasme) et regroupons les classes C_3 et C_4 (qui représenteront le fond).

Les tableaux 5.1 et 5.2 présentent les résultats des différentes classifications pixellaires en une étape effectuées dans l'espace RGB par les algorithmes des k-moyennes et de Fisher (sur la composante la plus significative) en fonction de différents paramètres.

Paramètres		$Indice_{cytoplasme}$	$Indice_{noyau}$
Cytoplasme3c	Noyau4c	40,7 %	59,8 %
Cytoplasme3c	Noyau5c	27,9 %	70,1 %
Cytoplasme4c	Noyau4c	60,6 %	59,8 %
Cytoplasme4c	Noyau5c	48,1 %	70,1 %
Cytoplasme5c	Noyau4c	69,6 %	59,8 %
Cytoplasme5c	Noyau5c	57,6 %	70,1 %

TAB. 5.1 – Résultats des classifications pixellaires effectuées en une étape par l’algorithme des k-moyennes dans l’espace RGB en fonction de différents paramètres.

Paramètres		$Indice_{cytoplasme}$	$Indice_{noyau}$
Cytoplasme3c	Noyau4c	31,9 %	53,6 %
Cytoplasme3c	Noyau5c	40,2 %	66,9 %
Cytoplasme4c	Noyau4c	70,5 %	53,6 %
Cytoplasme4c	Noyau5c	42,1 %	66,9 %
Cytoplasme5c	Noyau4c	68,3 %	53,6 %
Cytoplasme5c	Noyau5c	40,2 %	66,9 %

TAB. 5.2 – Résultats des classifications pixellaires effectuées en une étape par l’algorithme de Fisher sur la composante bleue de l’espace RGB en fonction de différents paramètres.

Afin de ne pas surcharger ce manuscrit, nous ne présentons pas les tableaux des classifications pixellaires effectuées par l’algorithme de Fisher sur les autres composantes de l’espace RGB , mais donnons cependant les résultats obtenus avec les meilleurs paramètres. Pour la composante rouge, il s’agit de cinq classes pour le cytoplasme ($Indice_{cytoplasme}=64$ %) et de quatre classes pour le noyau ($Indice_{noyau}=64,9$ %). Pour la composante verte, il s’agit de cinq classes pour le cytoplasme ($Indice_{cytoplasme}=41,3$ %) et de cinq classes pour le noyau ($Indice_{noyau}=63$ %).

Tous ces résultats nous permettent de montrer que dans l’espace RGB , la meilleure classification pixellaire en une étape est obtenue avec l’algorithme des k-moyennes avec comme paramètres : cinq classes pour le cytoplasme et cinq classes pour le noyau. Mais la principale information dont nous disposons sur de telles images étant la couleur, nous pensons que le choix de l’espace de représentation couleur peut être très important. Nous allons donc à présent nous attacher à la sélection du meilleur espace de représentation couleur. Les tableaux 5.3 et 5.4 présentent les résultats des différentes classifications pixellaires effectuées en une étape dans l’espace de représentation couleur où elles obtiennent les meilleurs indices de reconnaissance, par l’algorithme des k-moyennes et par l’algorithme de Fisher (sur la composante la plus significative). Les différents espaces de représentation couleur qui ont été utilisés sont ceux présentés au chapitre 2, à savoir : RGB , XYZ , LUV , LAB , YIQ , YUV , YC_bC_r , YCh_1Ch_2 , $I_1I_2I_3$, HSL , LCH .

Comme précédemment, nous pouvons donner les résultats de classification pixellaire en une étape obtenus par l’algorithme de Fisher avec les meilleurs paramètres. Pour une classification sur la première composante d’un espace couleur, il s’agit de l’espace XYZ

Paramètres		Espace	$Indice_{cytoplasme}$	$Indice_{noyau}$
Cytoplasme3c	Noyau4c	YUV	44.3 %	73.4 %
Cytoplasme3c	Noyau5c	YCh_1Ch_2	23.3 %	72.6 %
Cytoplasme4c	Noyau4c	YC_bC_r	68.6 %	73.6 %
Cytoplasme4c	Noyau5c	YCh_1Ch_2	52.6 %	72.6 %
Cytoplasme5c	Noyau4c	YC_bC_r	67.8 %	73.6 %
Cytoplasme5c	Noyau5c	YCh_1Ch_2	49.6 %	72.6 %

TAB. 5.3 – Résultats des classifications pixellaires effectuées en une étape par l'algorithme des k-moyennes en fonction de différents paramètres et de l'espace de représentation couleur.

Paramètres		Espace	$Indice_{cytoplasme}$	$Indice_{noyau}$
Cytoplasme3c	Noyau4c	XYZ	42,6 %	66,7 %
Cytoplasme3c	Noyau5c	LCH	35,0 %	69,1 %
Cytoplasme4c	Noyau4c	XYZ	61,2 %	66,7 %
Cytoplasme4c	Noyau5c	LCH	37,5 %	69,1 %
Cytoplasme5c	Noyau4c	XYZ	64,3 %	66,7 %
Cytoplasme5c	Noyau5c	LCH	35,0 %	69,1 %

TAB. 5.4 – Résultats des classifications pixellaires effectuées en une étape par l'algorithme de Fisher en fonction de différents paramètres et sur la première composante de différents espaces de représentation couleur.

avec cinq classes pour le cytoplasme ($Indice_{cytoplasme}=64,5$ %) et de quatre classes pour le noyau ($Indice_{noyau}=63,5$ %). Pour une classification sur la deuxième composante, il s'agit de l'espace RGB avec quatre classes pour le cytoplasme ($Indice_{cytoplasme}=42,1$ %) et de cinq classes pour le noyau ($Indice_{noyau}=66,9$ %).

Nous illustrons à partir de la figure 5.3, le principe de la classification pixellaire en une étape sur des images microscopiques de cytologie bronchique qui a été retenu pour l'algorithme des k-moyennes. D'une part, nous effectuons un changement d'espace de représentation couleur et passons de l'espace RGB à YC_bC_r . Nous effectuons ensuite une classification pixellaire en quatre classes et fusionnons des classes selon un critère de distance caractérisé par la distance de la couleur moyenne de chaque classe par rapport au noir, de sorte à obtenir une bonne classification de la cellule et donc du cytoplasme. D'autre part, nous effectuons une classification pixellaire en quatre classes et fusionnons des classes selon un critère de distance caractérisé par la distance de la couleur moyenne de chaque classe par rapport au blanc, pour obtenir la classification du noyau. Le regroupement des deux résultats obtenus en parallèle en superposant l'image des noyaux à celle des cytoplasmes, nous donne une image microscopique classée.

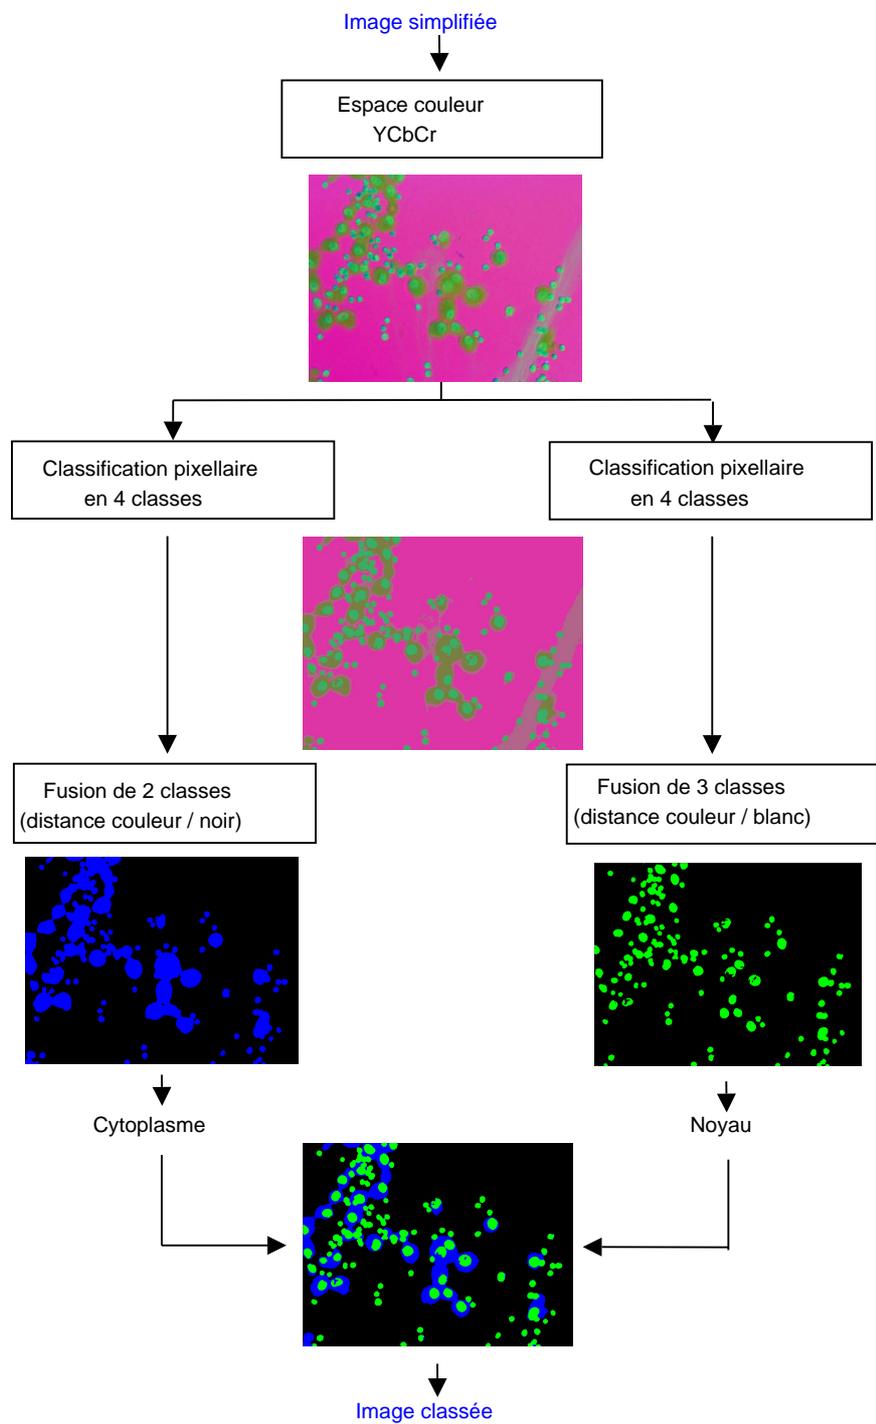


FIG. 5.3 – Illustration du principe de classification pixellaire en une étape retenue.

5.2.2 Classification pixellaire non supervisée en deux étapes

Une variante de la classification pixellaire présentée ci-dessus consiste à effectuer une classification pixellaire en deux étapes distinctes mais complémentaires comme le montre la figure 5.4.

1. La première étape consiste comme dans la classification de pixels précédente, à enchaîner une classification pixellaire en k classes et une fusion par classification ascendante hiérarchique (CAH) entre certaines classes selon un critère de distance caractérisé par la distance de la couleur moyenne de chaque classe par rapport au noir. Nous obtenons alors en fin de cette étape une première classe d'objets $C1$. Cette image intermédiaire est ensuite utilisée comme un masque ;
2. La deuxième étape consiste dans un premier temps à effectuer une classification pixellaire (que nous appelons conditionnelle) en k classes. Nous utilisons cette notation afin de montrer que seuls les pixels de l'image simplifiée qui appartiennent à la classe $C1$ dans l'image de masque, sont traités. Une fusion par classification ascendante hiérarchique est ensuite effectuée de la même manière que dans la classification pixellaire en une étape afin d'obtenir les objets d'une classe C_i .

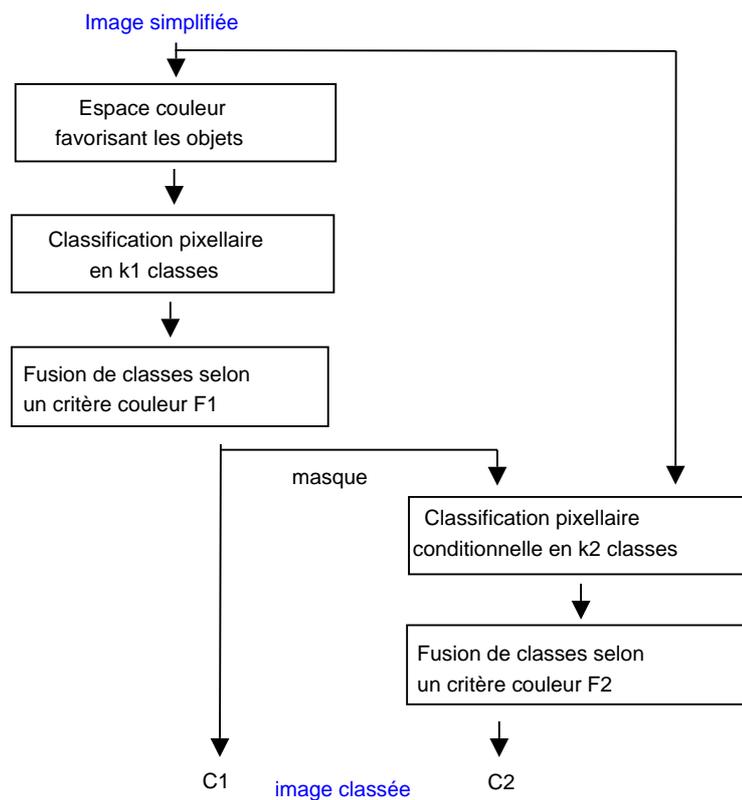


FIG. 5.4 – Principe de la classification pixellaire en deux étapes.

Les tableaux 5.5 et 5.6 présentent les résultats des différentes classifications pixellaires en deux étapes effectuées dans l'espace RGB par les algorithmes des k -moyennes et de Fisher (sur la composante la plus significative) en fonction de différents paramètres.

Paramètres		$Indice_{cytoplasme}$	$Indice_{noyau}$
Cytoplasme3c	Noyau2c	41,9 %	58,5 %
Cytoplasme3c	Noyau3c	48,9 %	36,9 %
Cytoplasme3c	Noyau4c	43,2 %	55,4 %
Cytoplasme3c	Noyau5c	47,4 %	44 %
Cytoplasme4c	Noyau2c	59,1 %	63,4 %
Cytoplasme4c	Noyau3c	66,7 %	43,5 %
Cytoplasme4c	Noyau4c	60,2 %	61,1 %
Cytoplasme4c	Noyau5c	65,3 %	48,8 %
Cytoplasme5c	Noyau2c	67 %	65,5 %
Cytoplasme5c	Noyau3c	75,2 %	45 %
Cytoplasme5c	Noyau4c	68,5 %	62,6 %
Cytoplasme5c	Noyau5c	73,6 %	50,8 %

TAB. 5.5 – Résultats des classifications pixellaires effectuées en deux étapes par l’algorithme des k-moyennes dans l’espace RGB en fonction de différents paramètres.

Paramètres		$Indice_{cytoplasme}$	$Indice_{noyau}$
Cytoplasme3c	Noyau2c	26,9 %	54,6 %
Cytoplasme3c	Noyau3c	31,6 %	35,5 %
Cytoplasme3c	Noyau4c	21,8 %	65,8 %
Cytoplasme3c	Noyau5c	23,1 %	63,4 %
Cytoplasme4c	Noyau2c	56,5 %	69,2 %
Cytoplasme4c	Noyau3c	65,3 %	54,2 %
Cytoplasme4c	Noyau4c	49,2 %	72,3 %
Cytoplasme4c	Noyau5c	50,8 %	72,4 %
Cytoplasme5c	Noyau2c	56,5 %	68,6 %
Cytoplasme5c	Noyau3c	64,6 %	52,4 %
Cytoplasme5c	Noyau4c	49,5 %	72,4 %
Cytoplasme5c	Noyau5c	50,8 %	72,3 %

TAB. 5.6 – Résultats des classifications pixellaires effectuées en deux étapes par l’algorithme de Fisher sur la composante verte de l’espace RGB en fonction de différents paramètres.

Comme nous avons pu le faire pour la classification de pixels en une étape, nous pouvons donner les résultats de classification pixellaire en deux étapes obtenus par l'algorithme de Fisher sur les autres composantes de l'espace RGB . Pour la composante rouge, il s'agit de cinq classes pour le cytoplasme ($Indice_{cytoplasme}=55,1\%$) et de cinq classes pour le noyau ($Indice_{noyau}=68,4\%$). Pour la composante bleue, il s'agit de quatre classes pour le cytoplasme ($Indice_{cytoplasme}=62,6\%$) et de quatre classes pour le noyau ($Indice_{noyau}=65,4\%$).

Nous constatons que les meilleurs résultats de classifications pixelaires effectuées en deux étapes dans l'espace de représentation couleur RGB sont obtenus avec l'algorithme de Fisher avec comme paramètres : quatre classes pour le cytoplasme et cinq classes pour le noyau et la composante verte de l'espace RGB . Comme nous avons pu le montrer précédemment, le changement d'espace influence de manière positive les résultats, nous allons alors à nouveau montrer son influence dans une classification pixellaire en deux étapes. Les tableaux 5.7 et 5.8 présentent les résultats des différentes classifications pixelaires effectuées en deux étapes dans l'espace de représentation couleur où elles obtiennent les meilleurs indices de reconnaissance, par l'algorithme des k-moyennes et par l'algorithme de Fisher (sur la composante la plus significative).

Paramètres		Espace	$Indice_{cytoplasme}$	$Indice_{noyau}$
Cytoplasme3c	Noyau2c	YUV	48,8 %	68,1 %
Cytoplasme3c	Noyau3c	YUV	54,4 %	54,3 %
Cytoplasme3c	Noyau4c	YC_bC_r	40,5 %	68,1 %
Cytoplasme3c	Noyau5c	YUV	50,9 %	60,1 %
Cytoplasme4c	Noyau2c	YCh_1Ch_2	69,5 %	74,4 %
Cytoplasme4c	Noyau3c	YC_bC_r	76 %	60 %
Cytoplasme4c	Noyau4c	YCh_1Ch_2	66,6 %	68,4 %
Cytoplasme4c	Noyau5c	YIQ	60,5 %	69,2 %
Cytoplasme5c	Noyau2c	YCh_1Ch_2	51,8 %	72,3 %
Cytoplasme5c	Noyau3c	YUV	71 %	67,1 %
Cytoplasme5c	Noyau4c	YUV	62,3 %	72,4 %
Cytoplasme5c	Noyau5c	YIQ	68,9 %	69,9 %

TAB. 5.7 – Résultats des classifications pixelaires effectuées en deux étapes par l'algorithme des k-moyennes en fonction de différents paramètres et de l'espace de représentation couleur.

Comme précédemment, nous pouvons donner les résultats de classification pixellaire en deux étapes obtenus par l'algorithme de Fisher avec les meilleurs paramètres. Pour une classification sur la deuxième composante d'un espace couleur, il s'agit de l'espace RGB avec cinq classes pour le cytoplasme ($Indice_{cytoplasme}=50,8\%$) et de cinq classes pour le noyau ($Indice_{noyau}=72,3\%$). Pour une classification sur la troisième composante, il s'agit de l'espace HSL avec cinq classes pour le cytoplasme ($Indice_{cytoplasme}=59,9\%$) et de cinq classes pour le noyau ($Indice_{noyau}=69,8\%$).

Une illustration du principe de classification pixellaire en deux étapes qui a été retenu pour l'algorithme des k-moyennes est alors présentée sur la figure 5.5 sur la même

Paramètres		Espace	$Indice_{cytoplasme}$	$Indice_{noyau}$
Cytoplasme3c	Noyau2c	XYZ	45,3 %	64,6 %
Cytoplasme3c	Noyau3c	RGB	54 %	52,1 %
Cytoplasme3c	Noyau4c	$I_1I_2I_3$	32,8 %	69,6 %
Cytoplasme3c	Noyau5c	XYZ	40,3 %	67,8 %
Cytoplasme4c	Noyau2c	$I_1I_2I_3$	53,8 %	72 %
Cytoplasme4c	Noyau3c	$I_1I_2I_3$	69,3 %	60,8 %
Cytoplasme4c	Noyau4c	YCh_1Ch_2	51,1 %	71 %
Cytoplasme4c	Noyau5c	YCh_1Ch_2	53 %	70,8 %
Cytoplasme5c	Noyau2c	$I_1I_2I_3$	57,3 %	71,9 %
Cytoplasme5c	Noyau3c	$I_1I_2I_3$	70,7 %	58,9 %
Cytoplasme5c	Noyau4c	YCh_1Ch_2	56,1 %	71,1 %
Cytoplasme5c	Noyau5c	$I_1I_2I_3$	50,9 %	72,1 %

TAB. 5.8 – Résultats des classifications pixellaires effectuées en deux étapes par l’algorithme de Fisher en fonction de différents paramètres et sur la première composante de différents espaces de représentation couleur.

base que précédemment. Nous commençons donc par effectuer un changement d’espace de représentation couleur de RGB à YCh_1Ch_2 . La première étape consiste alors en une classification pixellaire en 4 classes, puis une fusion de classes selon un critère de distance caractérisé par la distance de la couleur moyenne de chaque classe par rapport au noir, afin d’obtenir une image comportant les objets cytoplasmiques. Pour plus de commodité, cette même image est ensuite re-labélisée afin de représenter un masque pour l’étape suivante (les pixels correspondant aux cytoplasmes ont alors une valeur égale à 255). Dans la deuxième étape, nous effectuons une classification pixellaire en deux classes sur l’image simplifiée mais en ne traitant que les pixels ayant une valeur égale à 255. Puis nous effectuons une fusion de classes selon un critère de distance caractérisé par la distance de la couleur moyenne de chaque classe par rapport au blanc afin d’obtenir les objets nucléaires. En superposant l’image des noyaux à celle des cytoplasmes, nous obtenons une image microscopique de cytologie bronchique classée.

En conclusion, cette étape de classification pixellaire non supervisée nous a permis d’obtenir une image classée avec les différents objets que l’on souhaitait voir classifiés et dont les résultats sont illustrés dans le tableau 5.9. Ce tableau présente les résultats des classifications pixellaires par ordre de mérite décroissant pour chaque algorithme dans un espace couleur et avec les paramètres pour lesquels il obtient les indices de reconnaissance les plus importants. Nous en déduisons que l’algorithme des k-moyennes offre dans l’espace YCh_1Ch_2 les meilleurs résultats. Notons également que l’approche de classification pixellaire en deux étapes s’avère très concluante puisque c’est avec celle-ci que tous les classifieurs non supervisés ont obtenus leur meilleur résultat.

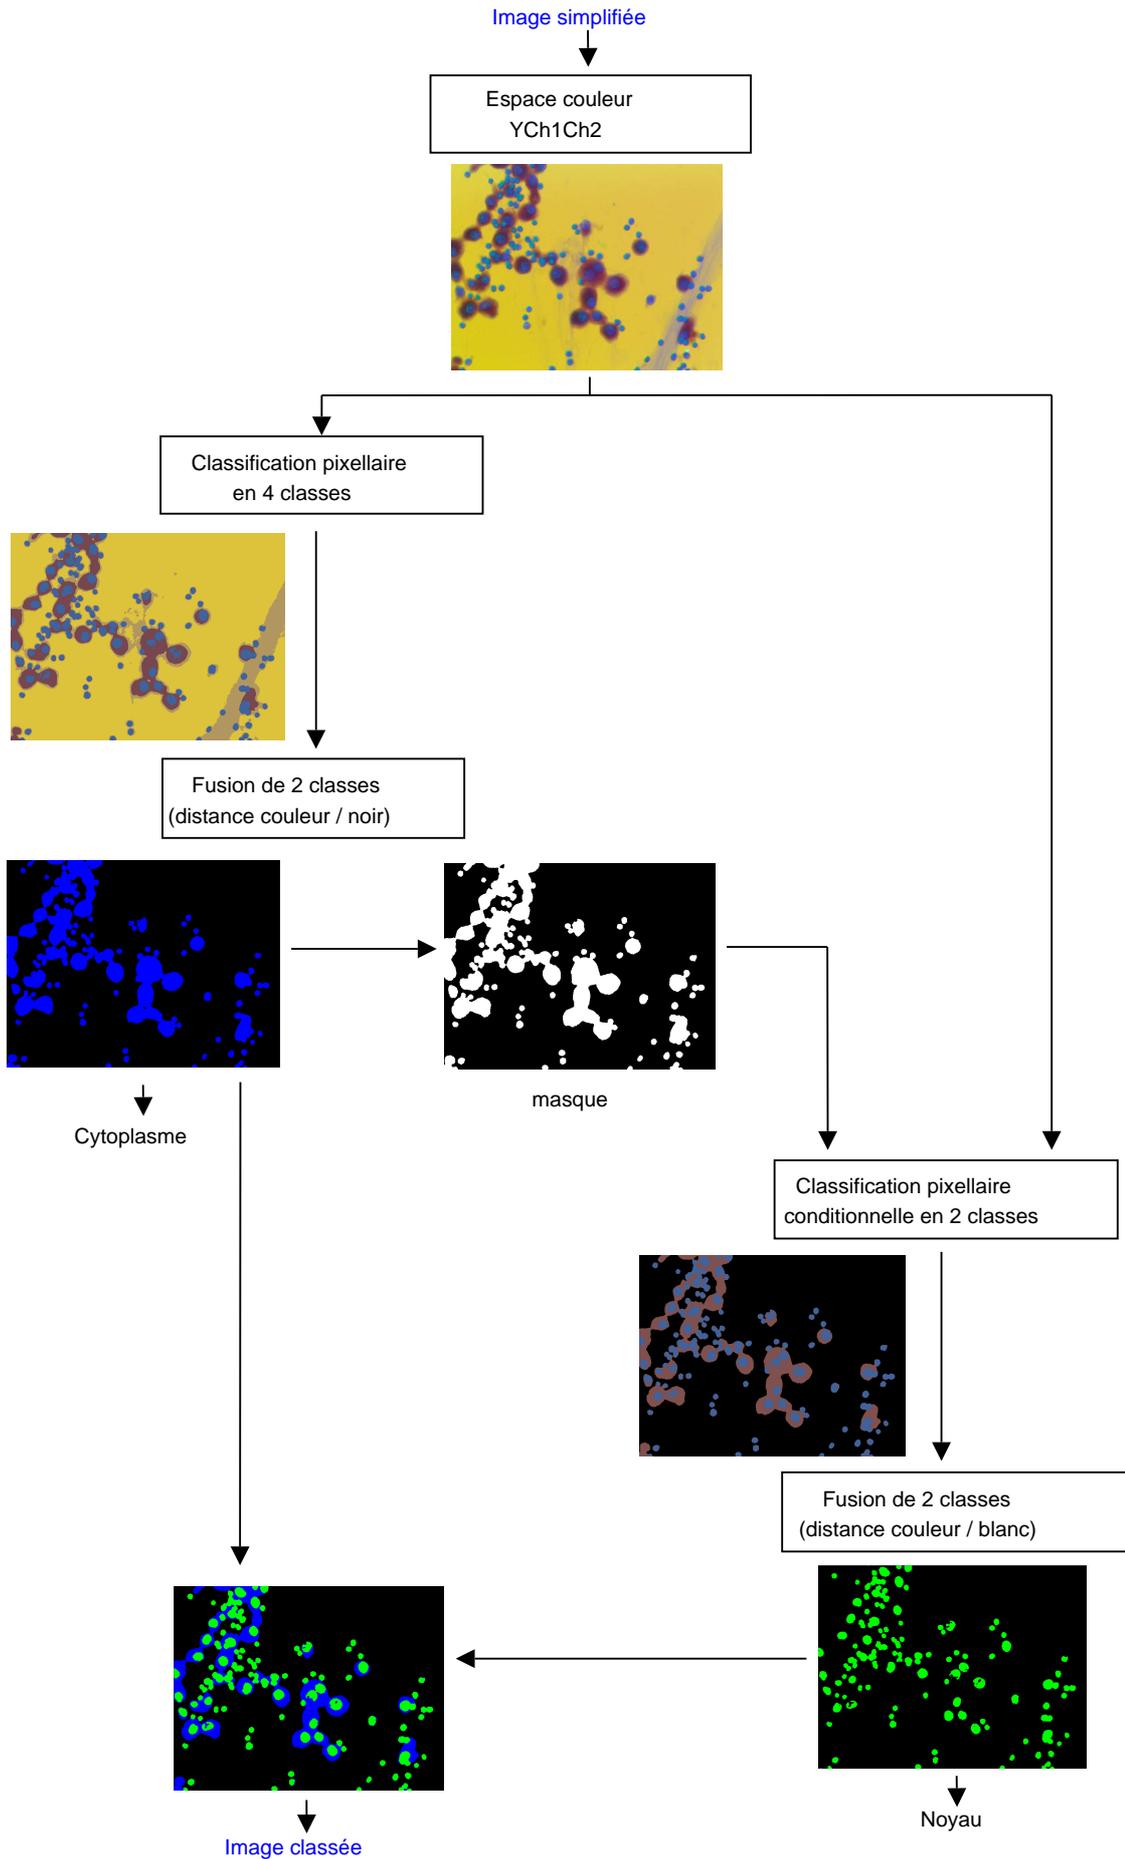


FIG. 5.5 – Illustration du principe de classification pixellaire en deux étapes.

Classifieur	Espace	$Indice_{cytoplasme}$	$Indice_{noyau}$
k-moyennes	YCh_1Ch_2	69.5 %	74.4 %
Fisher G	RGB	50.8 %	72.4 %
Fisher I_1	$I_1I_2I_3$	57.3 %	71.9 %
Fisher L	HSL	59.9 %	69.8 %

TAB. 5.9 – Résultats des différentes classifications pixellaires non supervisées.

5.3 Classification de pixels supervisée

Nous venons de définir dans la section précédente, les meilleurs paramètres pour les algorithmes des k-moyennes et de Fisher en fonction de l'espace de représentation dans lequel ils sont utilisés. De ce fait, nous avons montré l'influence du choix de l'espace de représentation couleur dans le processus de classification de pixels qu'il soit en une ou deux étapes. Nous allons dans cette section montrer dans quels espaces couleurs les classifieurs supervisés à savoir : les algorithmes de Bayes, des k plus proches voisins (k-PPV), des Machines à vecteurs de Supports (SVM) et des Réseaux de Neurones Multi-Couches (RNMC) obtiennent les meilleurs résultats. Nous aurions pu dans cette section utiliser comme précédemment une classification pixellaire en une ou deux étapes, mais nous avons choisi d'effectuer une simple classification pixellaire supervisée (sans étape de fusion) afin d'obtenir directement une image classée [MEURIE03C, MEURIE03B, MEURIE03A].

L'utilisation de méthodes de classification pixellaire supervisées entraîne la nécessité de disposer d'une base d'apprentissage faisant intervenir une segmentation de référence. La taille de la base d'apprentissage a une influence certaine sur les algorithmes supervisés. Certains, tels que les k-PPV et les SVM, réclament des puissances de calculs importantes et pour des grandes bases d'apprentissage, les temps d'apprentissage deviennent alors prohibitifs. Les figures 5.6, 5.7, 5.8 et 5.9 illustrent la variabilité des performances de classifieurs supervisés pour des bases d'apprentissage de taille différentes (réduction d'un facteur 3). La base d'apprentissage étant équilibrée entre les classes à apprendre.

Nous constatons d'après ces figures que l'augmentation du nombre d'exemples de la base d'apprentissage ne nous apporte pas d'amélioration significative dans la reconnaissance des objets et ce, quelque soit l'espace de représentation couleur ou l'algorithme utilisé (SVM ou k-PPV). Prenons l'exemple des SVM dans l'espace YCh_1Ch_2 où ils obtiennent les meilleurs indices de reconnaissance, le passage de 334 à 1002 exemples, entraîne une augmentation de 0,8 % que ce soit pour l'indice de reconnaissance du cytoplasme ou du noyau (figures 5.6 et 5.7). Il en est de même avec l'algorithme des k-PPV dans l'espace HSL où l'on obtient une augmentation de 0,2 % pour le cytoplasme et 1,6 % pour le noyau (figures 5.8 et 5.9). Le gain apporté n'est pas suffisamment important par rapport à l'énorme augmentation du temps d'apprentissage de la base et la complexité de la fonction de décision nouvellement produite. En conséquence de quoi, nous préférons les résultats obtenus avec une base de 334 exemples, pour la rapidité en apprentissage et en classification des classifieurs obtenus.

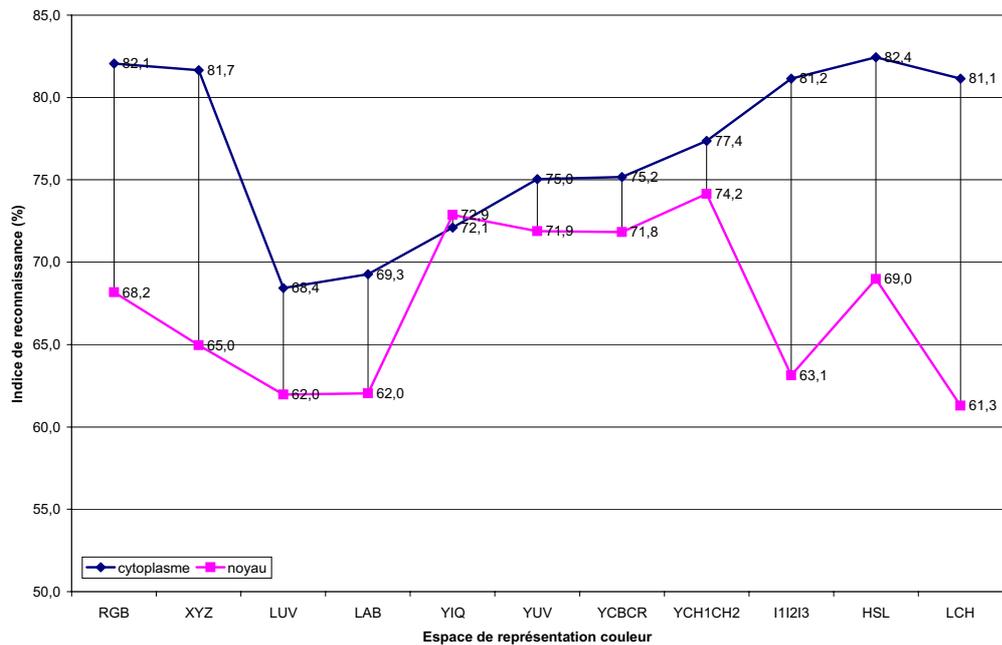


FIG. 5.6 – Influence de l'espace de représentation couleur pour une classification pixellaire effectuée par l'algorithme des SVM avec 334 exemples.

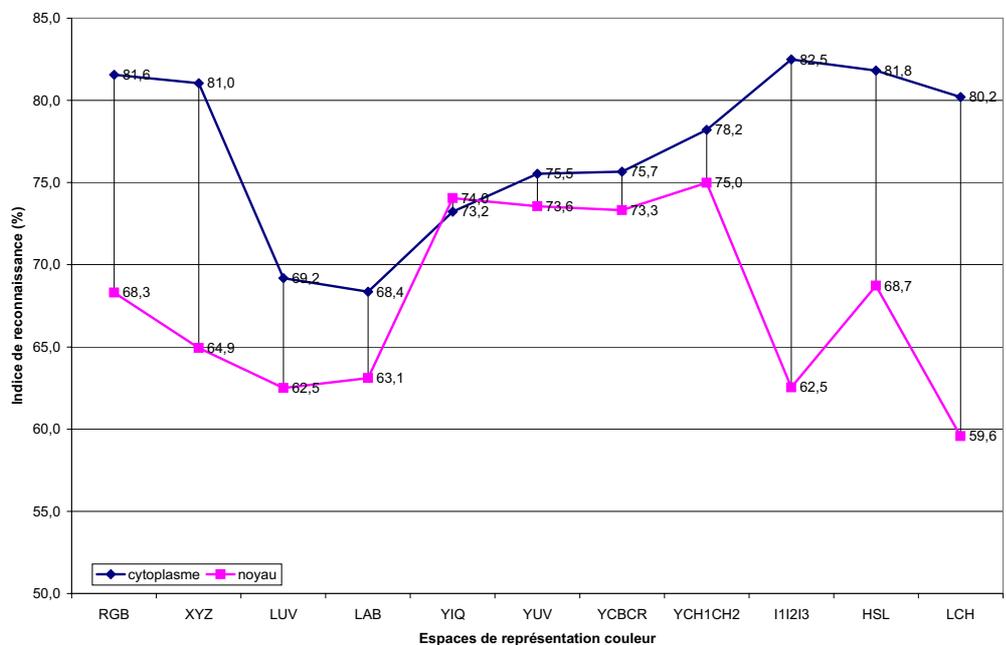


FIG. 5.7 – Influence de l'espace de représentation couleur pour une classification pixellaire effectuée par l'algorithme des SVM avec 1002 exemples.

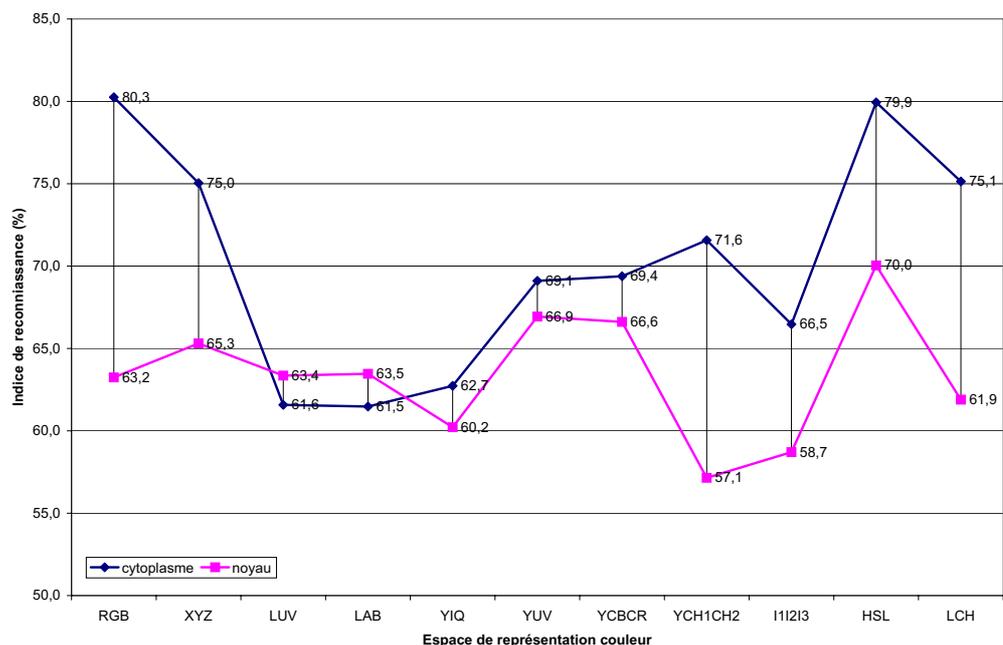


FIG. 5.8 – Influence de l’espace de représentation couleur pour une classification pixellaire effectuée par l’algorithme des k-PPV avec 334 exemples.

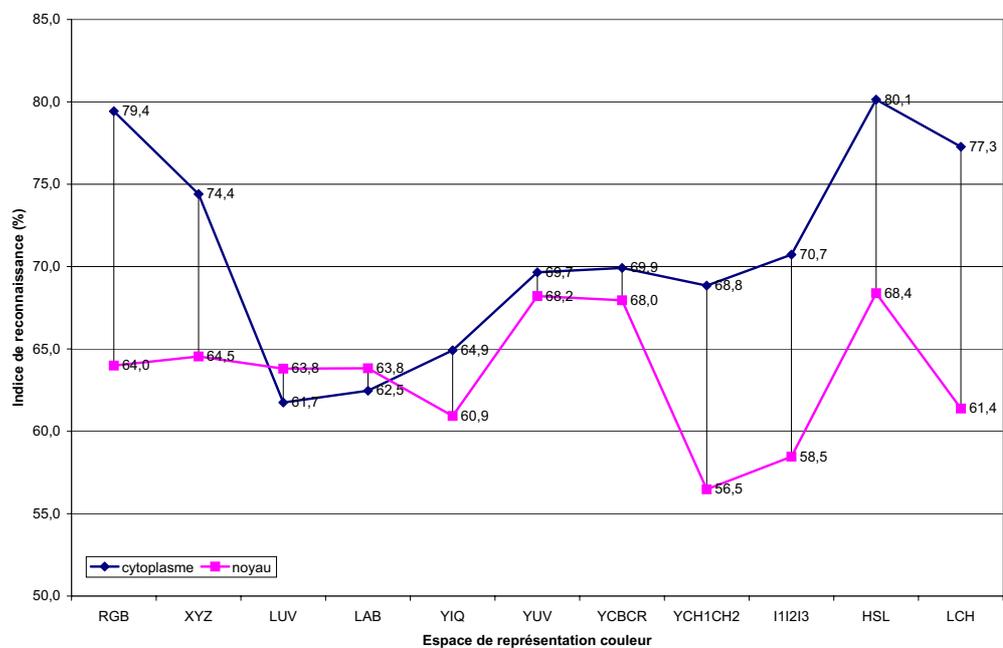


FIG. 5.9 – Influence de l’espace de représentation couleur pour une classification pixellaire effectuée par l’algorithme des k-PPV avec 1002 exemples.

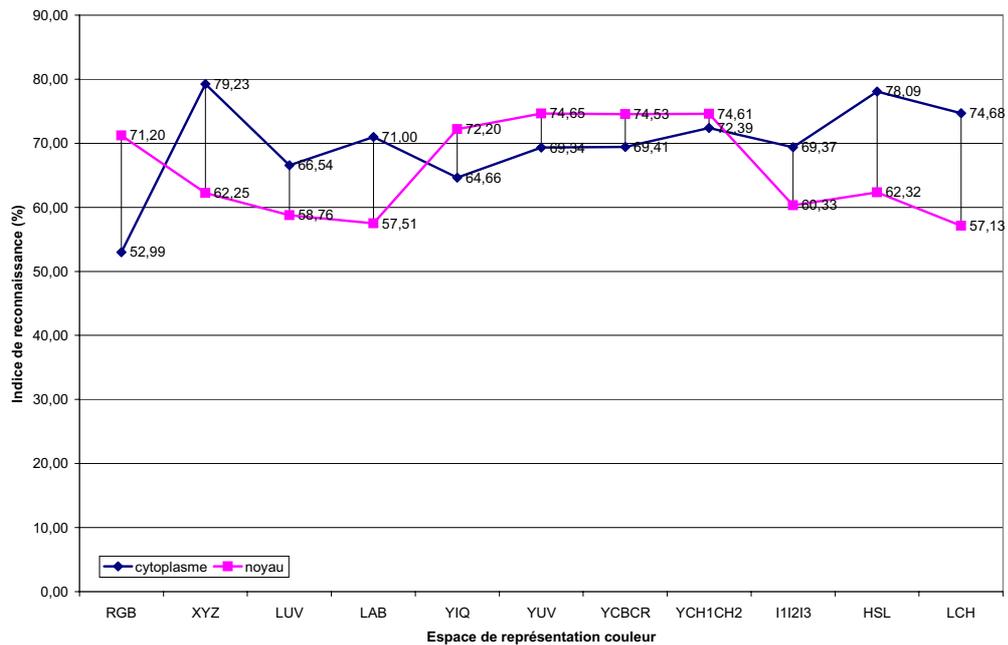


FIG. 5.10 – Influence de l'espace de représentation couleur pour une classification pixelaire effectuée par l'algorithme de Bayes.

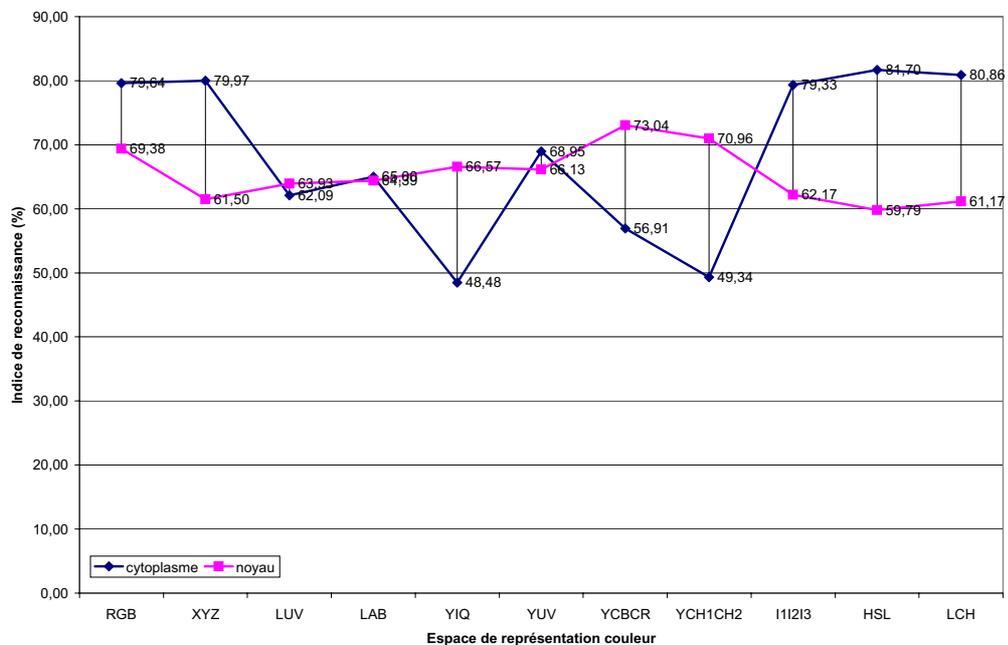


FIG. 5.11 – Influence de l'espace de représentation couleur pour une classification pixelaire effectuée par l'algorithme des RNNC.

Les figures 5.10 et 5.11 illustrent les résultats de classifications pixellaires obtenues respectivement avec l'algorithme de Bayes et l'algorithme des RNMC en fonction de l'espace de représentation utilisé. Nous constatons que l'algorithme de Bayes obtient les meilleurs résultats dans l'espace YCh_1Ch_2 et l'algorithme des RNMC dans l'espace YC_bC_r .

En conclusion, cette étape de classification pixellaire supervisée nous a permis d'obtenir une image classée avec les différents objets que l'on souhaitait voir classifiés et dont les résultats sont illustrés dans le tableau 5.10. Ce tableau présente les résultats des classifications pixellaires par ordre de mérite décroissant pour chaque algorithme dans un espace couleur et avec les paramètres pour lesquels il obtient les indices de reconnaissance les plus importants. Nous pouvons en déduire que l'algorithme des SVM effectué dans l'espace YCh_1Ch_2 fournit les meilleurs résultats de classification pixellaire supervisée.

Classifieur	Espace	$Indice_{cytoplasme}$	$Indice_{noyau}$
SVM	YCh_1Ch_2	77.4 %	74.2 %
Bayes	YCh_1Ch_2	72.4 %	74.6 %
RNMC	YC_bC_r	56.9 %	73 %
k-PPV	HSL	79.9 %	70 %

TAB. 5.10 – Résultats des différentes classifications pixellaires supervisées.

5.4 Combinaison de classifications pixellaires

Comme nous venons de le montrer, l'étape de classification pixellaire peut s'effectuer par une classification pixellaire non supervisée en une ou deux étapes, mais aussi par une classification pixellaire supervisée. En conséquence, comme l'illustre la figure 5.12, nous obtenons plusieurs résultats de classifications pixellaires pour une même image suivant la méthode et les algorithmes de traitement utilisés. Sur cette figure, les pixels noirs, bleus et verts correspondent respectivement au fond, au cytoplasme et au noyau. Nous montrons aussi sur la figure 5.12(j), la superposition de toutes les classifications pixellaires obtenues avec les différents classifieurs. Sur cette figure, les pixels de couleur jaune correspondent à ce que nous appelons des « zones d'incohérence », c'est-à-dire à des pixels où au moins un des classifieurs a donné un avis différent sur la classe à attribuer à un même pixel. Au vue de cette remarque, nous constatons que le choix du meilleur classifieur s'avère maintenant très délicat. C'est pourquoi, nous utilisons une étape de combinaison de classifications pixellaires permettant de s'affranchir de ce choix et d'utiliser la complémentarité qu'il peut exister entre les différents classifieurs pour augmenter la robustesse de notre classification. Ceci s'effectue en affectant une classe aux pixels incohérents [MEURIE04B, MEURIE04C, MEURIE03E, MEURIE04A].

Cette étape de combinaison de classifications pixellaires revient alors à effectuer une combinaison de classifieurs. On trouve dans la littérature un grand nombre de ces méthodes de combinaison [KITTLE98, JAIN00, RUTA00, ROLI02, ZOUARI02, CHOU00].

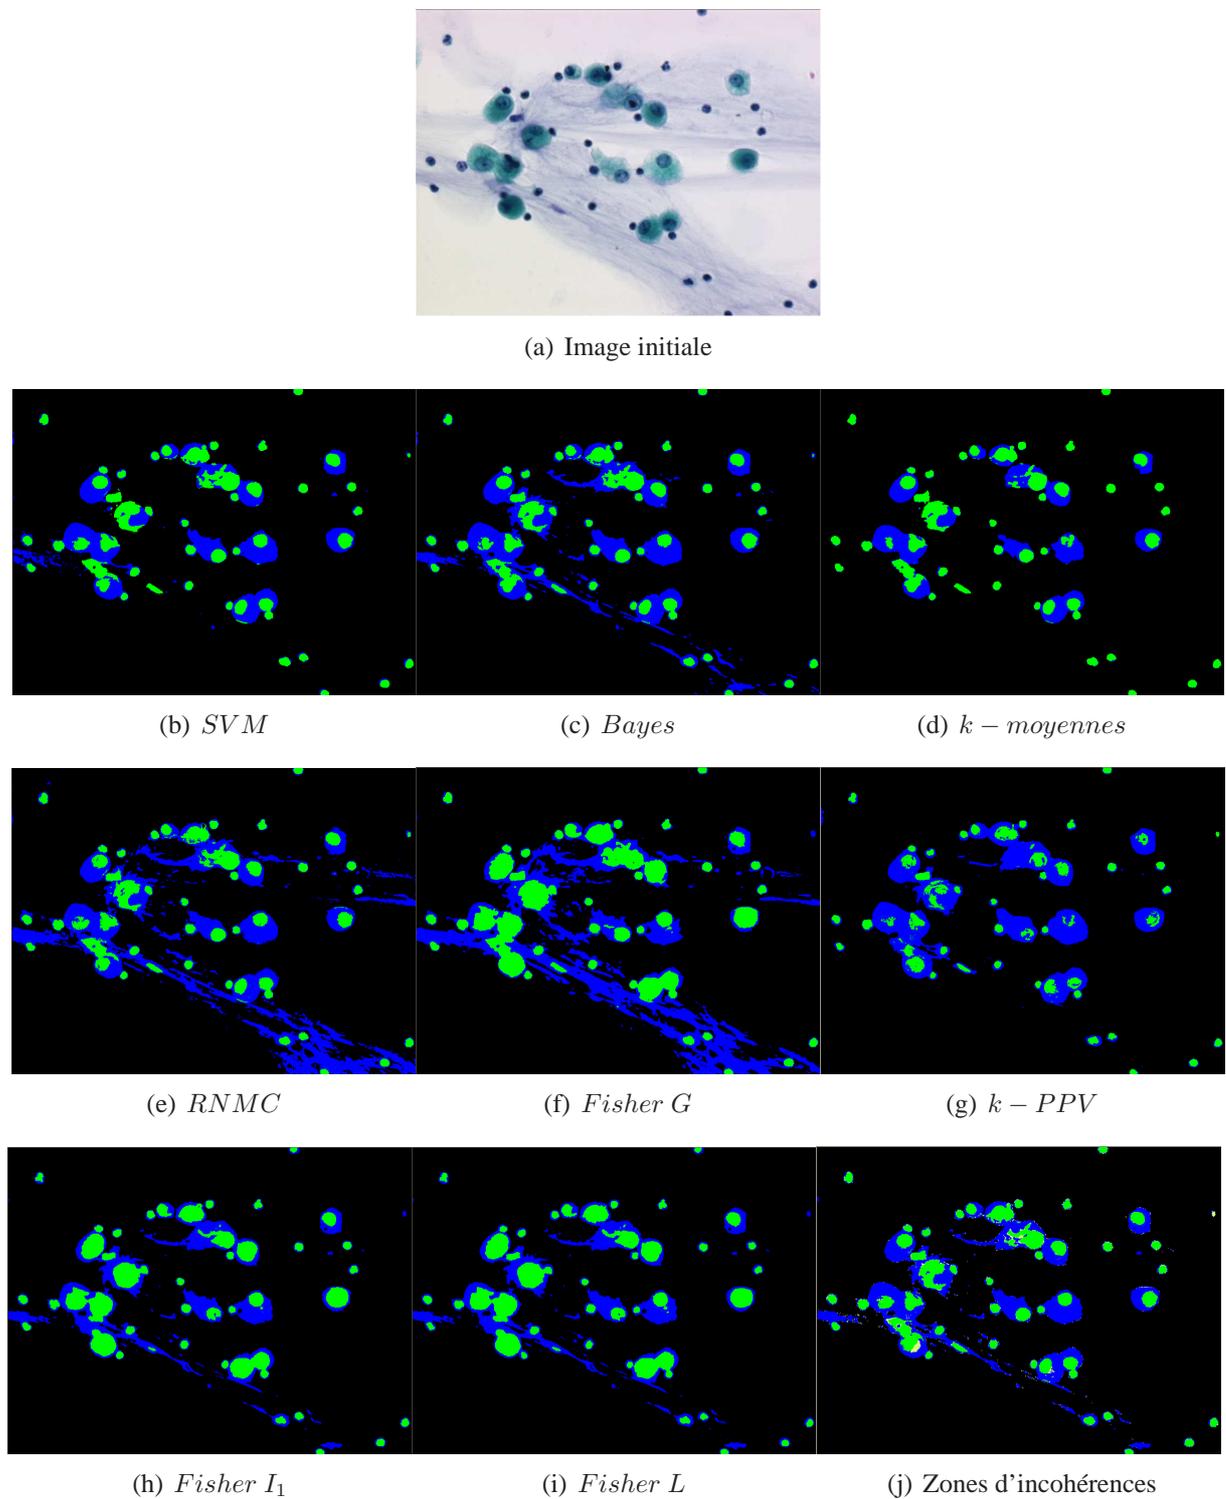


FIG. 5.12 – Résultats des différentes classifications pixellaires pour une image de la base de tests et (j) les zones d'incohérence (de couleur jaune).

KUNCHEVA [KUNCHE00] fait la distinction entre la fusion et la sélection de classifieurs. La fusion consiste à combiner tous les classifieurs de sorte à ce qu'ils participent tous à la prise de décision tandis que les méthodes de sélection quant à elles cherchent à combiner le meilleur sous ensemble de classifieurs en fonction des données présentes en entrée de la combinaison. DUIN [DUIN00] traite de la nature des classifieurs. Il effectue un distinguo entre les méthodes de combinaison utilisant des classifieurs hétérogènes et des classifieurs homogènes dits faibles, c'est-à-dire ayant la même structure mais entraînés sur des données différentes. XU [XU98] quant à lui effectue une différenciation entre les types de sorties des classifieurs (type classe, rang et mesure). JAIN [JAIN00] traite de la capacité d'apprentissage et d'adaptation des méthodes de combinaison. KITTLER ET AL. [KITTLER98] présentent un détail des méthodes de combinaison de classifieurs.

La figure 5.13 présente un schéma des différentes méthodes de combinaison parallèles de classifieurs inspiré de celui de ZOUARI [ZOUARI02] mais légèrement modifié de sorte à correspondre à notre propre schéma de combinaison de classifieurs.

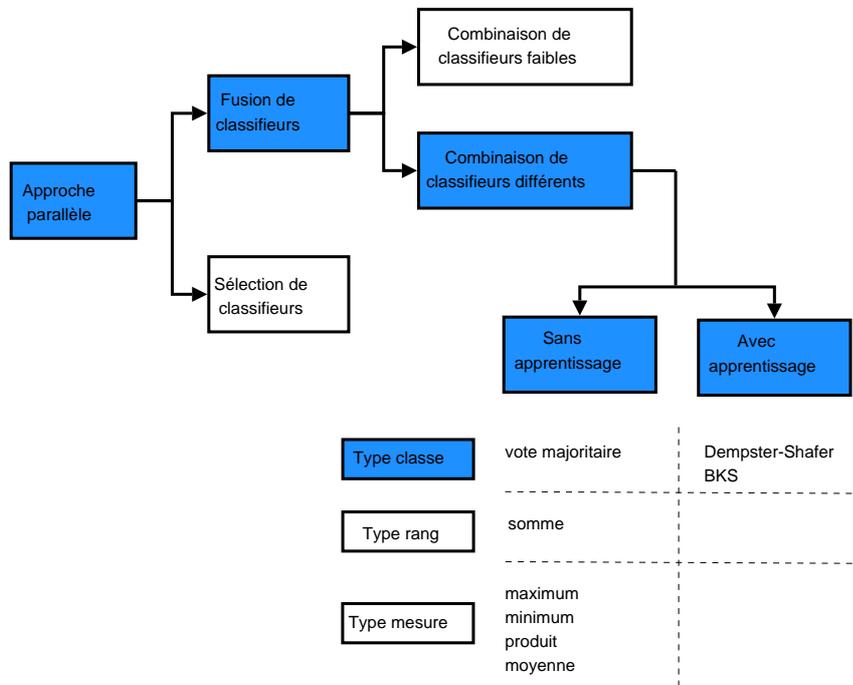


FIG. 5.13 – Schéma des méthodes de combinaison parallèle de classifieurs inspiré de celui de ZOUARI [ZOUARI02].

5.4.1 Indice de confiance

La réponse fournie en sortie de classification pixellaire est de type classe, c'est donc celle qui fournit le moins d'information parmi les trois types de réponse possibles. Pour pallier cet inconvénient et en vue d'augmenter la performance de l'étape de combinaison, nous l'avons couplée à un indice que nous avons appelé « indice de confiance ». Il est vrai que nous aurions pu directement appliquer des techniques de combinaison de classifications pixellaires existantes dans la littérature, mais il nous a semblé plus intéressant en

terme de qualité, de faire intervenir un indice de confiance attribuant un poids à chaque classification pixellaire obtenue séparément, de sorte à prendre en compte la qualité de celle-ci. Ainsi une classification pixellaire donnant de meilleurs résultats qu'une autre se verra attribuer plus d'importance dans l'étape de combinaison. Nous évaluons alors, toujours avec la méthode que nous avons proposée, chaque classifieur par rapport à une base d'apprentissage, de sorte à obtenir pour chacun d'entre eux, un indice $indice_j^i$ représentant la qualité de la classification du classifieur j sur la classe i (avec $i \in [1, k]$).

Ceci revient à définir pour un classifieur $j \in [1, n]$, le vecteur suivant :

$$indice_j = \begin{pmatrix} indice_j^0 \\ \vdots \\ indice_j^k \end{pmatrix} \quad (5.4)$$

Le tableau 5.11 présente pour chaque classe de l'image (de la base d'apprentissage), l'indice de confiance des différentes classifications pixellaires.

Classifieur	$Indice_{fond}$	$Indice_{cytoplasme}$	$Indice_{noyau}$
k-moyennes	97.7 %	52.1 %	74.6 %
SVM	96.3 %	73.2 %	73.4 %
Bayes	95.6 %	68.3 %	73.1 %
Fisher G	95.7 %	56.6 %	71.1 %
k-PPV	96.7 %	74.7 %	70.8 %
RNMC	95.7 %	64.4 %	69.1 %
Fisher I_1	96.4 %	56.3 %	67.6 %
Fisher L	96.5 %	56.1 %	67.1 %

TAB. 5.11 – Indices de confiance des différentes classifications pixellaires calculés sur des images de la base d'apprentissage.

5.4.2 Les méthodes de combinaison sans apprentissage

Les schémas classiques de combinaison utilisent habituellement plusieurs décisions provenant de classifieurs différents, chaque classifieur ayant fourni au préalable un indice d'appartenance à une classe. Dans le cas d'une classification pixellaire, nous pouvons directement appliquer cette stratégie et combiner les différentes sorties de classifieurs entre elles. Ces méthodes de combinaison utilisant des méthodes sans apprentissage peuvent être décrites comme suit :

Soit $E = \{e_1, \dots, e_n\}$ l'ensemble des n classifieurs utilisés. Chacun des classifieurs associe à un vecteur d'entrée x une classe C_i . Nous pouvons donc définir $E_{C_i}(x)$ l'ensemble des classifieurs, qui pour un vecteur d'entrée x lui associent tous la classe C_i :

$$E_{C_i}(x) = \{e_j \in E | e_j(x) = C_i\} \quad (5.5)$$

Nous avons évidemment $\cup\{E_{C_i}(x)\} = E$ car un classifieur e_j ne prend qu'une seule décision de type classe. A chaque ensemble $E_{C_i}(x)$ avec $i \in [1, k]$, nous pouvons associer

l'ensemble des indices de confiance pour chaque classifieur e_j . Cet indice correspond à la confiance accordée à la classification réalisée par le classifieur e_j lorsqu'il associe à x la classe C_i . Soit $I_{C_i}(x)$ l'ensemble de ces indices défini comme suit :

$$I_{C_i}(x) = \{indice_j^{C_i} | e_j \in E_{C_i}(x)\} \quad (5.6)$$

L'ensemble $I_{C_i}(x)$ correspond aux indices de confiance respectifs des classifieurs qui classent l'entrée x comme étant de la classe C_i . A partir de ces ensembles d'indices, nous pouvons calculer la probabilité d'appartenance de x à la classe C_i par la relation suivante :

$$P(C_i|x) = g(I_{C_i}(x)) \quad (5.7)$$

où g représente une fonction de combinaison parmi les fonctions suivantes : vote majoritaire (VM), minimum (MIN), maximum (MAX), somme (SOMME), moyenne (MOY) que nous pouvons retrouver dans les travaux de KITTLER ET AL. [KITTLER98].

On assigne ensuite au pixel p la classe C_k tel que :

$$P(C_k|x) = \underset{l}{argmax} P(C_l|x) \quad (5.8)$$

Les figures 5.14 et 5.15 présentent respectivement pour le cytoplasme et le noyau, l'influence de la règle de combinaison sans apprentissage en fonction du nombre de classifications pixellaires combinées. Nous constatons parmi toutes ces règles de combinaison utilisées (minimum, maximum, somme, produit, moyenne, vote majoritaire), que ce sont les fonctions vote majoritaire et somme qui donnent les meilleurs résultats lorsque l'on considère la cellule entière (cytoplasme et noyau). En ce qui concerne la reconnaissance du noyau, les indices augmentent légèrement avec l'augmentation du nombre de classifieurs combinés. Pour la reconnaissance du cytoplasme, un maximum sur les indices est obtenu pour trois classifieurs combinés. Nous concluons alors que la meilleure reconnaissance de la cellule entière est obtenue avec une combinaison des trois meilleurs classifieurs (que nous avons par ordre décroissant dans le tableau 5.11), c'est-à-dire avec les algorithmes k-moyennes, SVM et Bayes.

Dans le cadre du traitement d'image, l'information spatiale est une source d'information supplémentaire. Or pour le traitement d'un pixel, l'information de voisinage n'est pas prise en compte dans la combinaison des classifications de pixel. C'est pourquoi, il peut être intéressant de ne pas utiliser qu'une seule information pour décrire la sortie d'une méthode de classification mais plusieurs d'entre elles. Ce qui revient à prendre en considération toutes les classifications de pixels obtenues pour les pixels voisins au pixel central considéré. Pour un voisinage de taille i , la taille du vecteur associé à un classifieur est de $(8i + 1)$ (avec $i = 0$, on retrouve le cas simple avec seulement une classification par pixel).

Les figures 5.16 et 5.17 illustrent respectivement sur le cytoplasme et sur le noyau, l'influence de l'information de voisinage en fonction du nombre de classifications pixellaires combinées et en utilisant la somme comme règle de combinaison. Nous pouvons constater

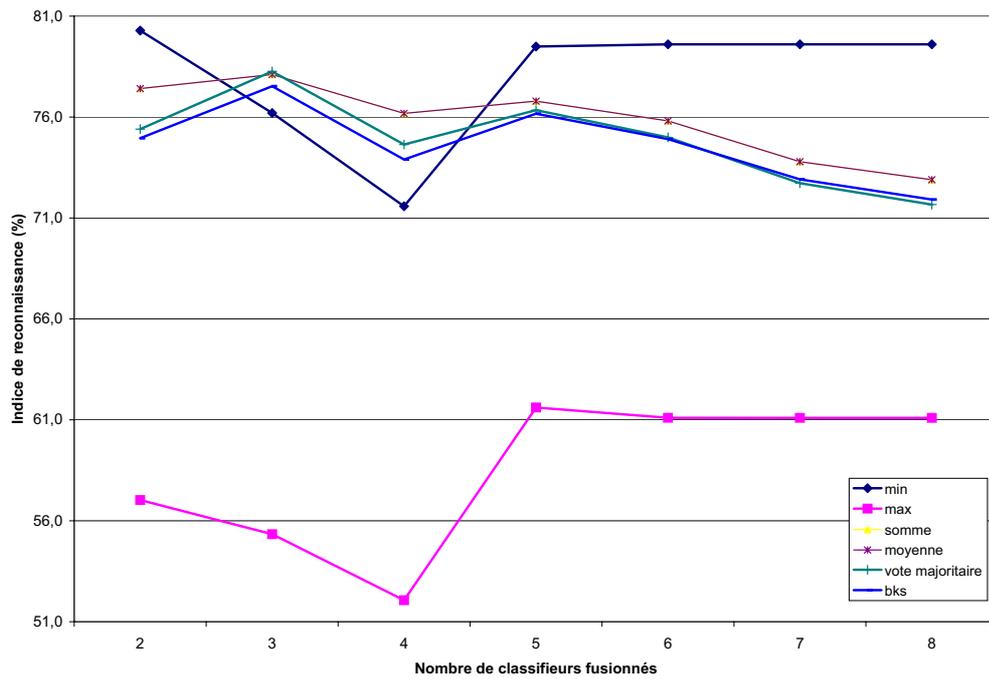


FIG. 5.14 – Influence de la règle de combinaison sur la reconnaissance du cytoplasme, en fonction du nombre de classifications pixellaires combinées.

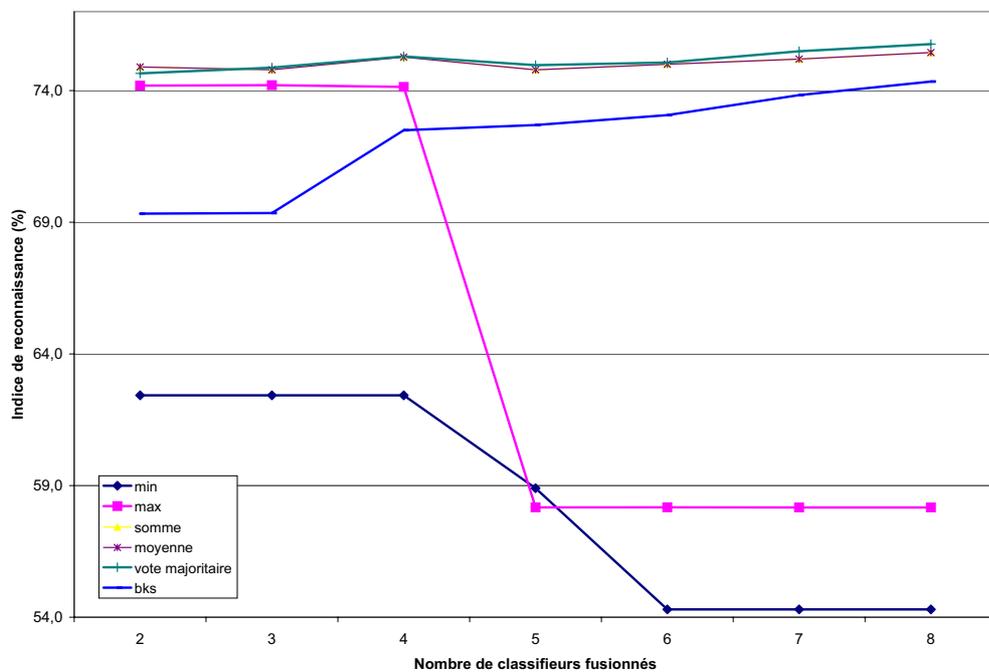


FIG. 5.15 – Influence de la règle de combinaison sur la reconnaissance du noyau, en fonction du nombre de classifications pixellaires combinées.

que la reconnaissance du noyau est augmentée en tenant compte de l'information sur 8 ou 16 voisins. La reconnaissance du cytoplasme quant à elle est augmentée ou diminuée avec l'information sur 8 voisins en fonction de la règle de combinaison utilisée. Au delà de cette limite, c'est à dire pour une information sur 16, 32 ou 64 voisins, nous rajoutons trop de divergence entre les classifieurs et les résultats sur la reconnaissance du cytoplasme et du noyau en sont diminués. Aux vues de ces résultats, nous concluons que la meilleure reconnaissance de la cellule est obtenue pour une information sur 8 voisins avec les trois meilleurs classifieurs et avec la somme comme règle de combinaison utilisée.

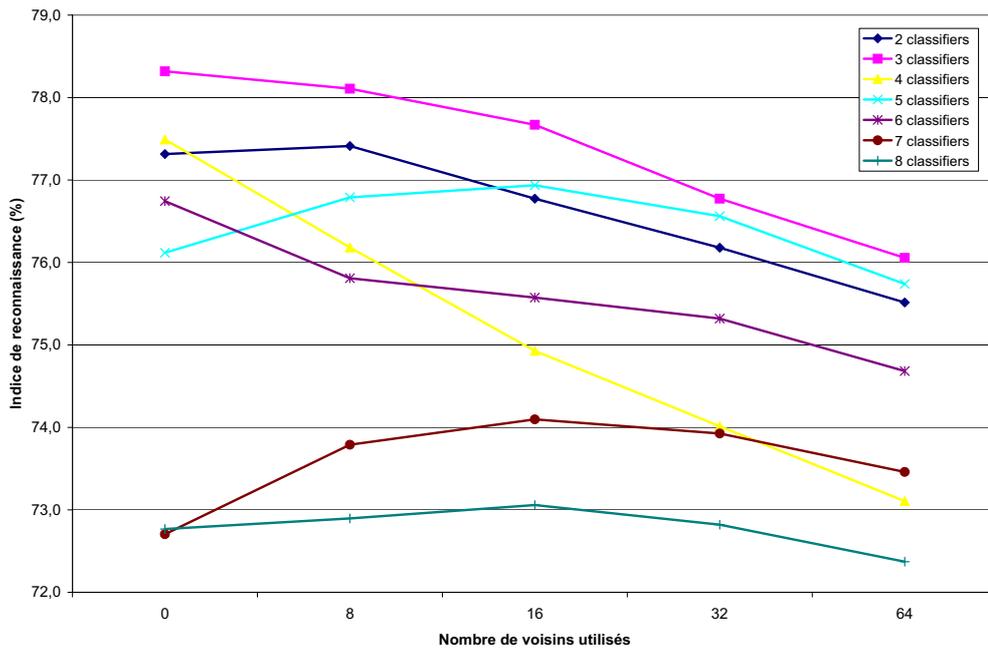


FIG. 5.16 – Influence du nombre de voisins sur la reconnaissance du cytoplasme, en fonction du nombre de classifications pixellaires combinées.

5.4.3 Méthodes de combinaison avec apprentissage

L'utilisation de méthodes de combinaison avec apprentissage est également utilisée pour combiner plusieurs classifieurs et donc plusieurs classifications pixellaires. Le Behaviour Knowledge Space (BKS) fait partie de ces méthodes. Il consiste à estimer la probabilité *a posteriori*, à partir d'une base d'apprentissage en calculant la fréquence de chaque classe correspondant à chaque combinaison des décisions de classifieurs. Pour un problème de k classes, lorsque $e_j(x)$ indique la décision de la classe fournie par le j^{eme} classifieur parmi les n utilisés, le vecteur de toutes les décisions de classifieurs $(e_1(x) \cdots, e_n(x))$ définit un point dans un espace discret à k dimensions appelé « espace de Behaviour Knowledge » (BKS). Chaque point du BKS peut être considéré comme une cellule. La cellule qui est l'intersection des décisions des classifieurs est appelée point focal. Pour chaque cellule, la valeur avec le plus grand nombre de modèles est estimée depuis une base d'apprentissage. Le schéma de combinaison du BKS affecte une telle

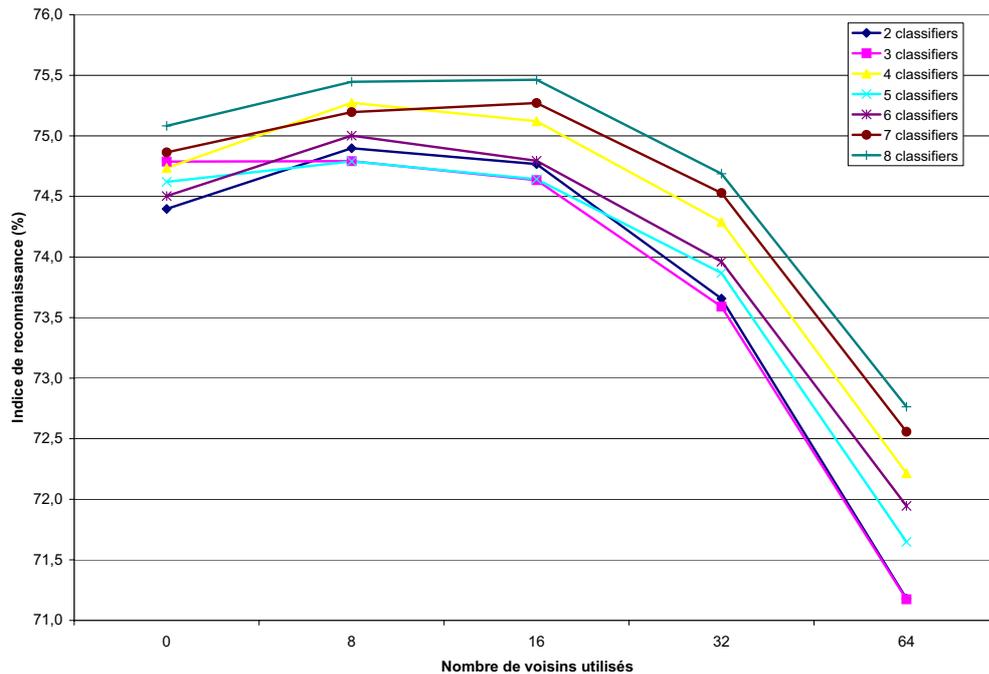


FIG. 5.17 – Influence du nombre de voisins sur la reconnaissance du noyau, en fonction du nombre de classifications pixellaires combinées.

classe à un modèle d'entrée x . Le BKS peut être considéré comme une « look-up table » qui définit le vecteur de décision de classifieurs d'une classe : il associe la classification finale à chaque combinaison des sorties de classifieur. La méthode requiert la construction d'une grande « look-up table » qui établit les renvois de chaque combinaison possible, des décisions de classifieurs. Afin de respecter la formulation originale de cette méthode de combinaison, nous avons pondéré la décision en fonction de leur indice de confiance.

Pour la règle de combinaison du BKS, la reconnaissance de la cellule diminue en fonction de l'augmentation de l'information de voisinage. Ceci peut être expliqué puisque le nombre de classifieurs ou le nombre de classes étant important, cela exige une base d'apprentissage importante pour obtenir une bonne chance de peupler chaque élément de la table de look-up. De plus, la base d'apprentissage doit être une bonne représentation des données non vues comme dans les expériences de [KUNCHE01], le BKS sera performant sur la base d'apprentissage, mais beaucoup moins sur la base de test. Cette remarque a aussi été vérifiée sur nos tests, mais nous pouvons néanmoins dire que nous obtenons de bons résultats avec le BKS sur un pixel seul avec une combinaison des trois meilleurs classifieurs comme le montre le tableau 5.12.

Nous avons également travaillé en collaboration avec CHRISTOPHE CHARRIER qui propose une méthode de combinaison de classifications pixellaires basée sur la théorie de Dempster Shafer ([MEURIE04A, LEZORA04]). La fonction de masse utilisée tient compte de l'incertitude associée à chaque plan couleur mais dans l'espace RGB (et donc diffé-

rent de celui que nous avons défini comme étant le meilleur pour chaque classification pixellaire).

Le Tableau 5.12 reprend les indices de qualité de la combinaison de classifications pixellaires obtenus avec différentes règles de combinaison. Les résultats sont très proches mais la règle de combinaison sans apprentissage employant la « somme » donne de meilleurs résultats (ce qui a déjà été expérimentalement énoncé par KITTLER [KITTL98]).

Classifieur	$Indice_{cytoplasme}$	$Indice_{noyau}$
Règle de combinaison non-supervisée (somme)	78.3 %	74.9 %
Règle de combinaison non-supervisée (vote majoritaire)	78.1 %	74.8 %
Règle de combinaison supervisée (BKS)	78.5 %	74.8 %
Combinaison par Dempster-Shafer	76.3 %	74.7 %

TAB. 5.12 – Résultats des différentes combinaisons de classifications pixellaires.

5.5 Intégration dans une approche morphologique

Nous venons de présenter dans ce chapitre différentes méthodes de classifications pixellaires dans un but de classer les différents objets d'une image. Ces méthodes peuvent donc être tout à fait utilisées seules, mais il s'avère qu'elles sont généralement utilisées pour l'extraction de marqueurs (comme l'illustre la figure 5.18), dans une stratégie de segmentation d'images couleur par morphologie mathématique. En effet, une telle stratégie de segmentation se décompose généralement en trois étapes séquentielles qui sont la simplification, l'extraction de marqueurs, et la croissance de régions que nous développons ci-après :

1. La première des étapes consiste en une phase de pré-traitement dont l'objectif est de simplifier l'image. Cette simplification peut consister à lisser l'image. Des opérateurs de seuillage ou de morphologie mathématique basés sur la reconstruction, permettent d'éliminer certains objets indésirables, selon les critères de taille, de forme ou de couleur ;
2. L'extraction de marqueurs est l'étape servant d'initialisation à l'étape suivante de localisation et qui consiste à extraire grossièrement les objets de l'image. Une connaissance *a priori* sur les caractéristiques des objets à traiter, permet d'utiliser des opérateurs de traitement d'images adaptés qui vont extraire partiellement ou totalement les objets sans toutefois être précis au niveau de la localisation ;
3. A partir des marqueurs obtenus à l'étape précédente, on utilise une opération bien connue de la morphologie mathématique appelée Ligne de Partage des Eaux (LPE). Celle-ci effectue une croissance de régions dans le but d'obtenir les régions correspondant aux objets segmentés.

Cette approche en tant que telle, offre généralement de bons résultats en segmentation, mais l'inconvénient est qu'elle n'est pas directement applicable à tous types d'images et plus particulièrement à des images ou des objets indésirables à l'extraction seraient

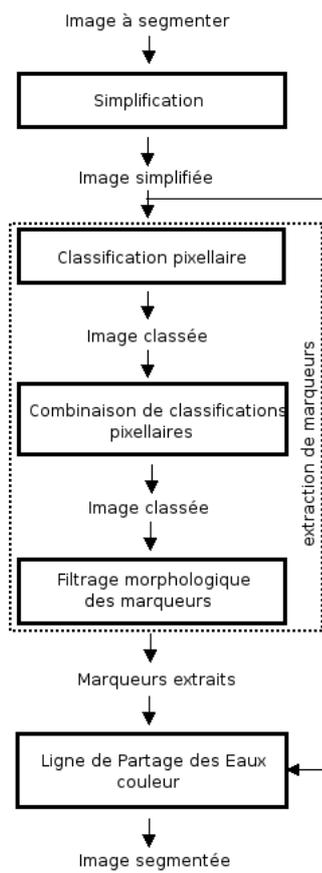


FIG. 5.18 – Stratégie de segmentation d'images 2D couleur.

présent dans le fond. Ceci est le cas pour la segmentation de cellules bronchiques car celles-ci sont récoltées dans un contexte très mucoïde (du mucus ayant le même aspect que certaines cellules ou des débris due à la préparation de la lame, peuvent être présents dans le fond). La classification d'objets cellulaires s'avère également difficile du fait de la superposition de certains « nuages de points » représentant la répartition spatiale des pixels dans un espace colorimétrique (un recouvrement entre le mucus et le noyau d'une part et le cytoplasme et le noyau d'autre part est souvent existant). Pour remédier à ces inconvénients, nous proposons d'intégrer l'approche par classification pixellaire que nous venons de présenter à la segmentation d'image couleur.

5.5.1 Simplification de l'image

L'étape de simplification de l'image utilisée en entrée de l'étape de classification pixellaire afin de réduire la sensibilité du classifieur à la présence de bruit et aussi utilisée pour le calcul de l'image de gradient intervenant dans la Ligne de Partage des Eaux. Dans le cadre de notre application, nous utilisons la technique de simplification basée sur les Equations aux Dérivées Partielles que nous avons présentée au paragraphe 5.1.

5.5.2 Filtrage morphologique des marqueurs

L'étape de filtrage morphologique des marqueurs peut être considérée comme une étape post-classification. Celle-ci permet de garder un sous ensemble de pixels valides appartenant au noyau ou au cytoplasme qui sera ensuite utilisé pour l'étape de croissance de régions. En effet, les frontières des objets n'étant pas délimitées de façon précise lors de l'étape de classification pixellaire, celles-ci sont considérées comme « non labélisées » et à partir de l'image des labels (parmi le fond, le cytoplasme, le noyau et les non étiquetés), une opération de filtrage morphologique est réalisée. Les pixels éliminés de cette façon correspondent soit à des petites régions appartenant à des anomalies (dans le cadre de la cytologie, cela peut correspondre à des débris ayant pu se trouver sur une lame de prélèvement lors de la phase de préparation), soit à des pixels mal classés (pouvant correspondre toujours dans le cadre de la cytologie à des frontières nucléo-cytoplasmiques ou de la chromatine transparente) dus au bruit inhérent dans les images ou aux difficultés d'affectation d'une classe dans l'étape de combinaison de classification pixellaire. Tous ces traitements sont effectués à partir d'une opération de morphologie mathématique simple d'érosion. Les opérations d'érosion des labels permettent d'augmenter la zone d'incertitude se situant aux abords des frontières des objets. La taille des différents objets n'étant pas identique, il est nécessaire de trouver le bon nombre d'érosions à effectuer afin d'optimiser le nombre de marqueurs valides. Une fois l'érosion des labels effectuée, certains pixels sont « non labélisés » et une opération de croissance de régions est alors nécessaire. Dans le cadre d'images microscopiques de cytologie bronchique, nous avons fixé expérimentalement le nombre d'érosions à une pour les frontières des noyaux et à quatre pour celles des cytoplasmes. A titre d'illustration, nous présentons en couleur noire sur la figure 5.19, les zones d'incertitude relatives aux cytoplasmes et aux noyaux obtenues suite à l'étape de filtrage morphologique des marqueurs.

Nous venons d'expliquer que les frontières des objets ne sont pas délimitées de façon précise lors de l'étape de classification pixellaire, et c'est pour cette raison que nous effec-

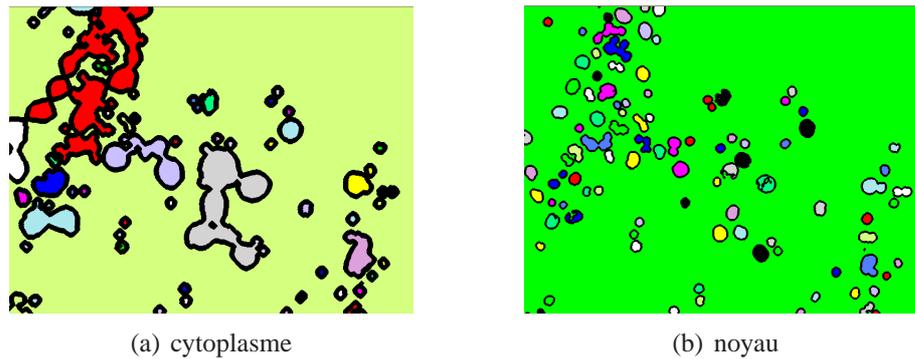


FIG. 5.19 – Zones d'incertitude sur les deux types d'objets à segmenter.

tuons une érosion sur ces dernières pour permettre à la croissance de régions de s'exécuter. On peut cependant adopter une tout autre approche. Nous avons montré dans la section consacrée à la combinaison de classifications pixellaires que les classificateurs ne donnent pas toujours le même avis sur la classe à attribuer à un pixel. Plutôt que de chercher à combiner les classificateurs pour ces zones d'incohérence inter-classificateurs, nous pouvons considérer que les zones d'incohérence des classificateurs sont les zones d'incertitude de la croissance de région. Dans ce cas la combinaison de classificateurs revient juste à effectuer l'intersection de leurs classifications et à ne pas labéliser un pixel classifié différemment par au moins deux classificateurs. La croissance de régions par LPE opérera alors uniquement dans les zones d'incohérence, ce qui évite d'avoir à fixer un nombre d'érosions.

5.5.3 Ligne de Partage des Eaux couleur

A l'aide des marqueurs obtenus précédemment, nous cherchons à localiser précisément les contours des régions. Pour cela, nous utilisons une Ligne de Partage des Eaux couleur [VINCEN91, MEYER92] appelée plus communément LPE couleur et composée de deux étapes [SHAFAR97] :

- l'extraction de marqueurs servant de germes à la croissance de la LPE. Cette extraction de marqueurs est réalisée par l'enchaînement de trois étapes qui sont : la classification pixellaire, la combinaison de classifications pixellaires et le filtrage morphologique de marqueurs. Les germes peuvent alors être produits par les deux approches que nous venons de présenter dans le paragraphe précédent ;
- une croissance qui utilise les germes précédemment extraits pour propager les étiquettes dans l'image selon une fonction d'agrégation.

La LPE couleur que nous utilisons est définie selon une fonction d'agrégation spécifique. Cette fonction définit la probabilité d'agrégation d'un pixel à une région. Elle est basée sur deux informations principales décrivant l'information spatiale de l'image : une information locale exprimée par le gradient couleur et une information globale donnée par une mesure de la couleur moyenne des régions décrivant l'homogénéité globale de celles-ci. La fonction d'agrégation est définie par [LEZORA02A, LEZORA02B] :

$$f(p, R) = (1 - \alpha)\|I(R) - I(p)\| + \alpha\|\nabla I(p)\| \quad (5.9)$$

où $I(R)$ dénote le vecteur donnant la couleur moyenne de la région R de l'image I , $I(p)$ le vecteur donnant la couleur d'un pixel p et $\nabla I(p)$ le gradient couleur. Cette fonction combine l'information locale (module du gradient couleur où ce gradient est calculé en utilisant le critère de DiZenzo [DIZENZ86]) et l'information globale (résultant d'une comparaison statistique entre la couleur d'un pixel p et une région voisine R calculée avec une distance de norme L_2). Durant le processus de croissance, chaque fois qu'un pixel est ajouté à une région R , la couleur moyenne de la région est mise à jour. L'image couleur et l'image gradient sont toutes deux normalisées afin que leurs valeurs soient dans la même gamme. α est un coefficient de pondération qui permet de modifier l'influence du critère local par rapport au critère global durant le processus de croissance [LEZORA00B]. Il est généralement fixé selon des connaissances *a priori* sur l'image mais une segmentation adaptable qui modifie la valeur de ce paramètre à chaque itération de la croissance étant plus appropriée, c'est cette dernière méthode que nous avons utilisée [LEZORA02B].

Classifieur	$Indice_{Cytoplasme}$	$Indice_{Noyau}$
k-moyennes	72.8 %	76.2 %
SVM	73.2 %	75.8 %
Bayes	71.1 %	76.7 %
Combinaison non-supervisée	76.5 %	76.4 %
Zones d'incertitude comme germes	78.2 %	75 %

TAB. 5.13 – Indice de segmentation finale.

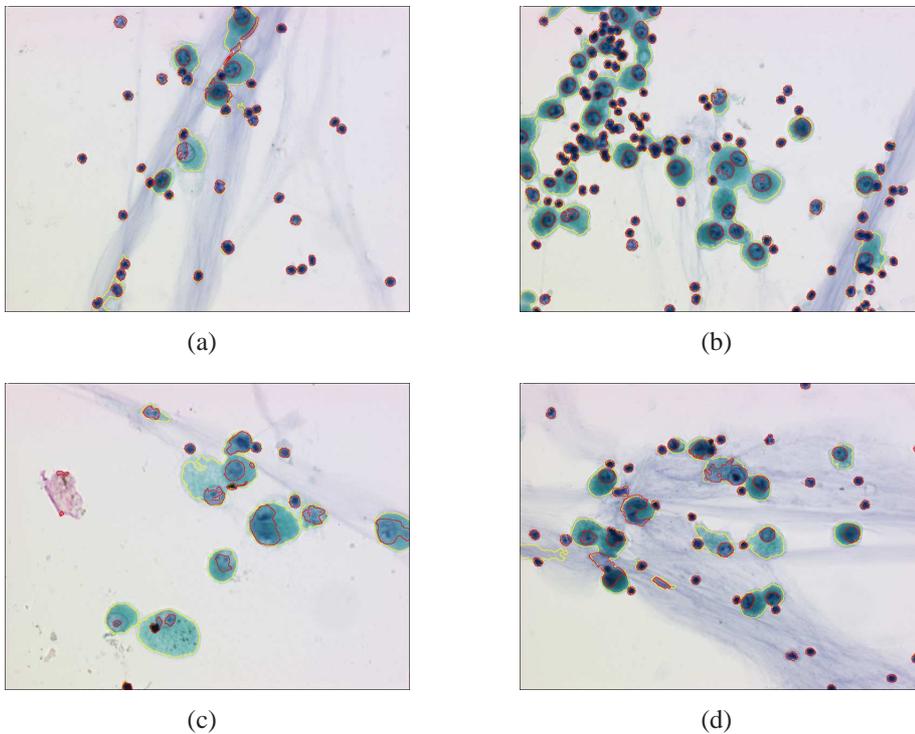


FIG. 5.20 – Quatre images de la base de tests segmentées.

Le tableau 5.13 et la figure 5.20 présentent respectivement le résultat de l'étape de segmentation de façon quantitative et le résultat avec les frontières colorées des objets

superposés. Dans ce tableau, nous présentons tout d'abord, les résultats de segmentation (classification pixellaire + LPE) pour les trois meilleurs classifieurs (k-moyennes, SVM et Bayes) et constatons que les k-moyennes donnent les meilleurs résultats. Nous présentons ensuite les résultats concernant la combinaison des trois meilleures classifications pixellaires suivies d'une LPE. Les résultats montrent que les indices de reconnaissance des objets sont augmentés par rapport à ceux des k-moyennes, SVM et Bayes pris seuls. Enfin, nous illustrons que l'utilisation des zones d'incertitude comme germes pour la LPE augmente l'indice de reconnaissance du noyau par rapport à celui obtenu avec la combinaison de classifications pixellaires, mais diminue légèrement celui du cytoplasme. Or nous rappelons que les experts en cytopathologie privilégient l'indice de reconnaissance du noyau. Nous concluons alors que les meilleurs résultats sont obtenus avec une combinaison des trois meilleurs classifications pixellaires, suivi d'une croissance de régions (les résultats sont aussi augmentés par rapport à la combinaison de classifications pixellaires seules puisque nous passons d'un indice de reconnaissance de 78,3 % pour le cytoplasme et 74,9 % pour le noyau à un indice de reconnaissance de 76,5 % pour le cytoplasme et de 76,4 % pour le noyau).

5.6 Conclusion

Nous avons proposé dans cette partie une approche hybride de segmentation d'images couleur. Chacune des étapes importantes de cette approche a été détaillée dans le cadre de la segmentation d'images microscopiques de tumeurs bronchiques. Nous avons proposé une méthode de classification pixellaire non-supervisée nommée classification pixellaire en deux étapes fournissant de meilleurs résultats qu'une classification pixellaire non supervisée classique. Nous avons constaté que dans le cadre d'une classification pixellaire seule, les algorithmes des k-moyennes et des SVM utilisés dans l'espace YCh_1Ch_2 donnent respectivement les meilleurs résultats en classification de pixels non-supervisée et supervisée. Notons que l'utilisation de plusieurs classifieurs entraîne généralement des problèmes de combinaison puisque des contradictions entre des classificateurs voient le jour. Il est alors nécessaire de trouver une solution permettant de les arbitrer. La combinaison de classifications pixellaires (obtenue à partir de plusieurs classifieurs) peut fournir de meilleurs résultats qu'une classification pixellaire obtenue par un seul classifieur. Nous avons ainsi montré dans cette partie, l'amélioration des résultats par l'utilisation d'une combinaison de classifications pixellaires et d'information de voisinage. La meilleure combinaison pour notre application en imagerie microscopique consiste en l'utilisation d'une combinaison des trois meilleurs classificateurs avec l'information du voisinage (8 voisins) pour une règle de combinaison sans apprentissage de type « somme ». L'étape de croissance de région incluse dans notre approche est réalisée par une Ligne de Partage des Eaux couleur. Celle-ci permet de mieux délimiter les régions correspondant aux objets segmentés et donc d'augmenter le taux de reconnaissance de nos objets. Pour une meilleure quantification de résultats obtenus, nous avons défini une méthode d'évaluation particulièrement adaptée à la microscopie mais pouvant être sous certaines restrictions, employée à d'autres applications où les objets à segmenter sont reconnaissables par leur couleur même issus d'un milieu bruité. Les résultats de segmentation calculés à partir de cette méthode d'évaluation montrent un indice de reconnaissance de 76,5 % pour le cytoplasme et de 76,4 % pour le noyau. Nous concluons sur le fait que cette approche de segmentation peut facilement

s'adapter à tous types de cytologie car seule l'étape de classification de pixels doit être modifiée.

DEUXIÈME PARTIE

**SEGMENTATION D'IMAGES COULEUR
PAR HIÉRARCHIE DE PARTITIONS**

MÉTHODES POUR UNE SEGMENTATION HIÉRARCHIQUE

Sommaire

6.1 Différents modèles de structuration d'image	97
6.2 Méthodes morphologiques	104
6.3 Conclusion	117

NOUS présentons tout d'abord dans ce chapitre les différents modèles de structuration d'une image. Nous parlerons ainsi de pyramides régulière et irrégulière, de représentation par arbre ou par graphe. Nous insisterons sur la construction d'une pyramide de graphe avec la définition d'un Graphe d'Adjacence de Régions puisque nous utiliserons ce dernier dans les méthodes de segmentation et de simplification d'images couleur que nous proposerons ultérieurement. Dans un second temps, nous présentons des méthodes de segmentation hiérarchique basées sur des critères connectifs tels que les zones plates ou quasi-plates, les connexions par sauts, la Ligne de Partage des Eaux. Mais ces méthodes de segmentation hiérarchique présentant d'une façon générale des images sur segmentées dans les niveaux les plus bas de la pyramide, nous présenterons différentes approches de fusion de régions proposées dans la littérature.

6.1 Différents modèles de structuration d'image

En traitement d'images, la façon la plus simple de représenter une image est de travailler à une résolution donnée. Néanmoins, dans le cadre plus spécifique qu'est la segmentation, nous avons l'habitude de travailler à différentes résolutions. Nous parlons alors de multi résolution revenant à considérer cela comme une décomposition hiérarchique de l'image. Une représentation multi résolution revient alors à fournir un ensemble d'images dérivées de l'image initiale ou chacune d'elles contient moins d'information que la précédente.

6.1.1 Pyramides régulières

6.1.1.1 Pyramide gaussienne et laplacienne

Un des systèmes de représentation de l'approche par multi résolution est la pyramide gaussienne introduite par BURT ET ADELSON [BURT83, BURT84]. Cette pyramide est

constituée d'un empilement successif d'images obtenues à différents niveaux selon un processus de filtrage et de sous échantillonnage. Le nombre de niveaux de la pyramide dépend de la taille de l'image initiale puisqu'une réduction de la taille de l'image s'effectue à chaque niveau. L'image obtenue au niveau $k+1$ est réduite d'un facteur quatre par rapport au niveau k puisque quatre pixels de l'image du niveau k sont représentés par un seul au niveau $k+1$. Le niveau 0 correspond à l'image initiale et le niveau K à la dernière image de la pyramide constituée d'un seul pixel. Le nom de cette pyramide vient du fait que le filtrage est approximé par un filtrage de type gaussien dont le noyau de convolution est généralement de taille $5*5$.

Une autre approche pyramidale fortement liée à la précédente est la pyramide laplacienne. Celle-ci n'est en fait que le dual de la pyramide Gaussienne, ceci revenant à dire que chaque niveau k de la pyramide laplacienne est obtenu par la différence pixel à pixel entre le niveau k et le niveau $k+1$ de la pyramide gaussienne. Comme nous l'avons indiqué précédemment, la taille de l'image dans une pyramide Gaussienne varie entre deux niveaux successifs, il convient alors d'étendre le niveau $k+1$ au niveau k afin de pouvoir obtenir le dual de la pyramide laplacienne.

La figure 6.1 illustre une approche pyramidale obtenue par réduction de la taille de l'image. La taille de l'image initiale est fixée au préalable puis à chaque augmentation de niveau, l'image est réduite d'un facteur α revenant ainsi à diminuer sa résolution.



FIG. 6.1 – Multi résolution obtenue par réduction de la taille de l'image.

6.1.1.2 L'arbre quaternaire

Nous venons de voir qu'une représentation multi résolution d'une image peut se faire sous la forme de pyramides (gaussienne et laplacienne), mais elle peut également se faire sous forme arborescente. Nous pouvons distinguer deux approches possibles dans cette forme de représentation : l'approche ascendante (« bottom-up ») et descendante (« top-down »). Pour décrire ces deux approches, nous reprenons les termes de feuilles et de racine couramment utilisés [TA04]. L'approche ascendante consiste à partir des feuilles de l'image pour arriver à la racine par une technique que nous pouvons caractériser de fusion-génération. Pour ce faire, nous partons de l'image où chaque pixel correspond à une région et fusionnons ensuite celles lui étant adjacentes selon un critère d'uniformité prédéfini de sorte à arriver, au fur et à mesure de la construction, à une image ne contenant plus qu'une seule région. A contrario, l'approche descendante revient à partir de la racine

de l'arbre pour arriver aux feuilles par une technique de division-génération. Nous partons de l'image ne contenant qu'une seule région et, au fur et à mesure que nous descendons dans la pyramide, nous divisons l'image en différentes régions pour arriver au maximum à une image où chaque pixel correspond à une région.

Cette présentation des deux approches arborescentes étant faite, nous allons pouvoir maintenant présenter l'arbre quaternaire (« quadtree ») [SAMET80, HOROWI74]. Ce type de représentation est très utilisé pour la recherche de composantes connexes et fonctionne selon une approche descendante en utilisant la propriété de récursivité du maillage carré. L'image initiale doit alors être de taille $2^n \times 2^n$. La stratégie de l'arbre quaternaire consiste ensuite, à partir de l'image initiale, à diviser de façon récursive chaque bloc non homogène en quatre sous blocs selon un certain critère d'homogénéité choisi au préalable. L'obtention de ces quatre sous blocs est obtenue par une division horizontale puis verticale de l'image. Pour une économie en temps de calcul, il est possible d'agir sur la profondeur de l'arbre en se fixant un critère d'arrêt sur la taille minimum d'un bloc en dessous de laquelle nous ne souhaitons plus effectuer de division ou encore en affectant un seuil sur le critère d'homogénéité. Comme cela a été fait par BERTOLINO [BERTOL95] et DOMBRE [DOMBRE03], nous présentons le résultat du découpage de l'arbre quaternaire sur la figure 6.2. La figure de gauche représente l'image initiale, les deux autres correspondant respectivement au résultat du découpage du quadtree et à cette même image re-colorisée (chaque région est caractérisée par sa moyenne couleur).

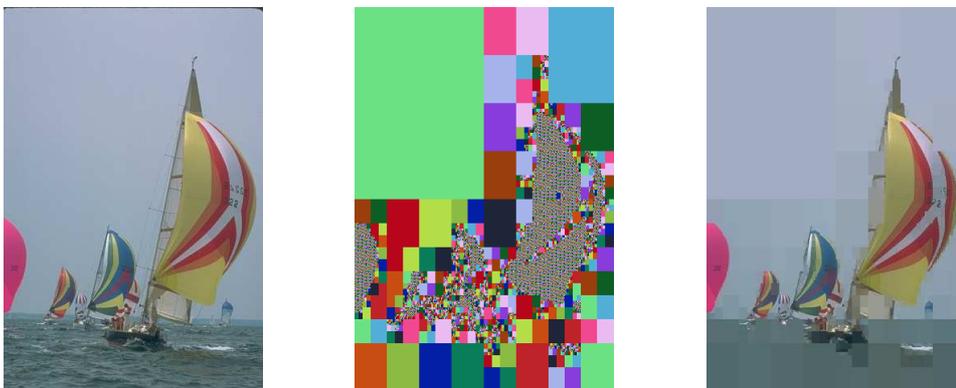


FIG. 6.2 – Principe de découpage de l'arbre quaternaire.

6.1.2 Pyramides irrégulières

Un second système de représentation de l'approche par multi résolution est la pyramide irrégulière appelée aussi pyramide de graphes. Ce type de représentation est très utilisé en segmentation car il bénéficie de moins de contraintes géométriques [BISTER90], préserve la connexité et limite le nombre de régions à un certain niveau de la pyramide. Au niveau 0, c'est-à-dire à la base de la pyramide, l'image initiale de taille $(L \times H)$ comporte $(L \times H)$ régions (chaque pixel représente une région de l'image). La pyramide irrégulière, tout comme la pyramide régulière, se construit par un empilement successif de niveaux à la différence près que la taille de l'image au niveau $k + 1$ ne décroît pas par rapport à celle

du niveau k . La figure 6.3 illustre une représentation pyramidale obtenue par simplification de l'image. Les images produites à différents niveaux voient leurs détails diminués en fonction de l'augmentation du niveau.



FIG. 6.3 – Multi résolution obtenue par simplification de l'image.

La représentation d'une image peut se faire autrement que sous forme matricielle et notamment sous forme de graphe. Cette représentation est très utilisée en traitement d'images car elle permet de modéliser les relations topologiques existantes entre les pixels ou les régions.

Définition (Graphe) Un graphe $G = \{N, A\}$ est composé d'un ensemble de noeuds $N = \{n_1, n_2, \dots, n_n\}$ et d'un ensemble d'arêtes $A = \{a_1, a_2, \dots, a_m\}$ où chacune d'entre elles relie un couple de noeuds.

6.1.2.1 Graphe de frontières de régions

Le graphe de frontières de régions (« Region Boundary Graph ») est un graphe où chaque arête correspond à un ensemble de pixels associé à la frontière entre deux régions adjacentes et où chaque noeud représente un point de jonction entre deux frontières ou plus. La figure 6.4 illustre un graphe de frontières de régions d'une image présentant plusieurs régions. Notons que la définition du type de connexité (par exemple en 4-voisinage ou en 8-voisinage) est fondamentale pour la construction du graphe de frontières de régions même si cette remarque n'est pas mise en valeur dans l'image de la figure 6.4 du fait de son découpage un peu particulier.

6.1.2.2 Graphe d'adjacence de régions

Le graphe d'adjacence de régions (« Region Adjacency Graph ») n'est rien d'autre que le dual du graphe de frontières de régions vu précédemment [PAVLID77, KROPAT95]. C'est un graphe non orienté où les noeuds de ce dernier représentent les régions de l'image. Le lien unissant deux noeuds d'un graphe (i.e deux régions adjacentes) est appelé arête. Le graphe d'adjacence est très souvent valué c'est à dire que des valeurs numériques généralement positives sont attribuées aux sommets ou aux arêtes du graphe. Ces valeurs, appelées aussi coût $C(n_1, n_2)$, sont calculées à partir d'une fonction nommée fonction de

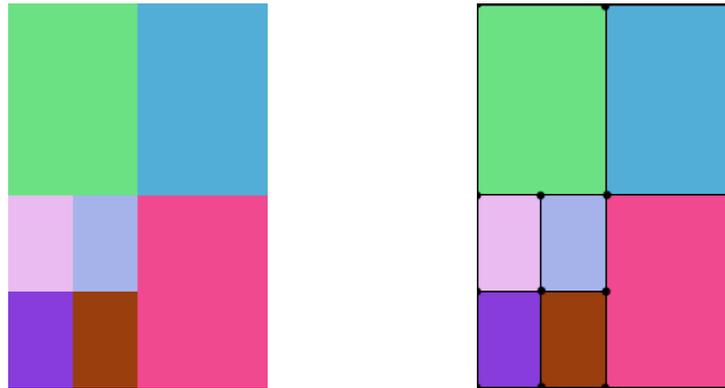


FIG. 6.4 – Graphe des frontières de régions.

coût traduisant la similarité entre deux noeuds reliés par une arête. La figure 6.5 illustre ces notions en représentant le Graphe d'Adjacence de Régions pour une image divisée en 7 régions. La figure 6.6 présente une image de voiliers, cette même image découpée en plusieurs régions par un quadtree, et son Graphe d'Adjacence de Régions où chaque noeud est re-colorisé par rapport à la couleur moyenne de la région correspondante.

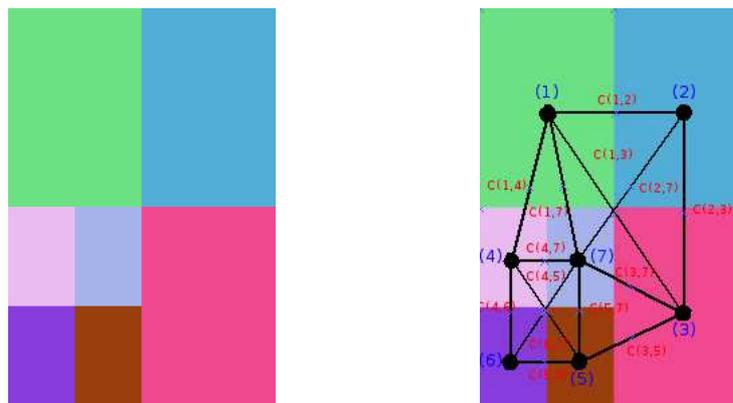


FIG. 6.5 – Notations et Graphe d'Adjacence de Régions.

6.1.2.3 Construction d'une pyramide de graphes

Nous allons à présent définir ce que nous appellerons, dans la suite de ce manuscrit, une hiérarchie ou pyramide de graphes. Comme nous avons pu le voir précédemment pour une pyramide régulière de type gaussienne, il s'agit d'un empilement successif d'images obtenues à différents niveaux de résolution, à la différence près qu'il ne s'agit plus ici d'un empilement d'images mais de graphes. La construction d'une telle pyramide entraîne à chaque niveau l'obtention d'un nouveau graphe avec un nombre de noeuds qui tend à diminuer au fur et à mesure que l'on se rapproche du sommet de celle-ci. Afin de décider quel noeud sera conservé pour le niveau suivant de la pyramide, deux valeurs sont ajoutées à la définition d'un graphe et plus précisément associées à chaque noeud. Il s'agit d'une

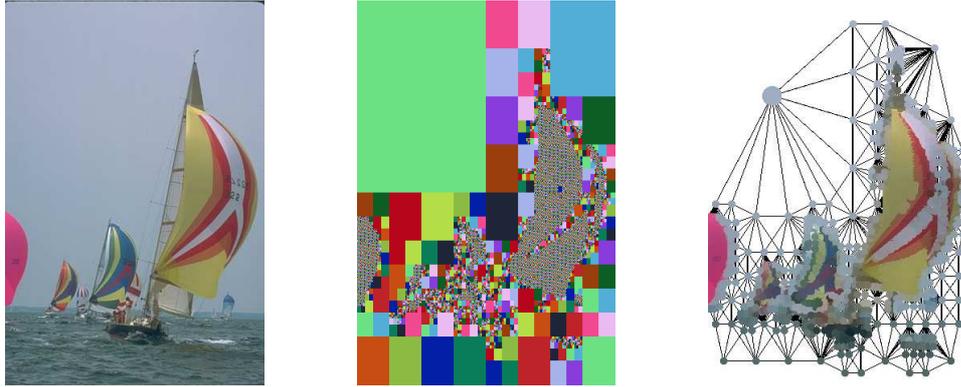


FIG. 6.6 – Graphe d'Adjacence de Régions.

part de sa qualité relative, c'est-à-dire dire sa capacité « a priori » de survivre au processus de décimation et d'autre part d'une information telle que la couleur ou le niveau de gris associé à la région correspondante. Le processus de décimation transformant un graphe G_k en G_{k+1} tel que $|N_{k+1}| < |N_k|$ peut être effectué selon deux approches différentes :

1. La première approche que l'on peut retrouver dans [MEER89], consiste à effectuer le processus de décimation selon deux règles à savoir : la décimation doit être maximale afin de permettre une convergence rapide vers un graphe simplifié, ce qui fut amélioré par JOLION [JOLION03]. Pour toute paire de noeuds (i, j) appartenant à une même arête au niveau k , i et j ne peuvent pas tous les deux exister au niveau supérieur $k + 1$. La deuxième règle implique que tout noeud d'un niveau k doit être lié à un noeud du niveau $k + 1$. La figure 6.7 extraite des travaux de LALLICH ET AL. [LALLIC03] illustre bien ce processus de décimation. Sur la figure 6.7(a) est représenté le graphe initial G_k , sur la figure 6.7(b) le graphe obtenu à la première itération dans lequel les noeuds de couleur noire représentent les noeuds ayant survécu au processus de décimation et les noeuds de couleur grise à leurs voisins respectifs. A cette itération la seconde règle n'est pas validée, une deuxième itération représentée sur la figure 6.7(c) est alors nécessaire pour extraire un troisième noeud complétant ainsi le nouveau graphe G_{k+1} ;

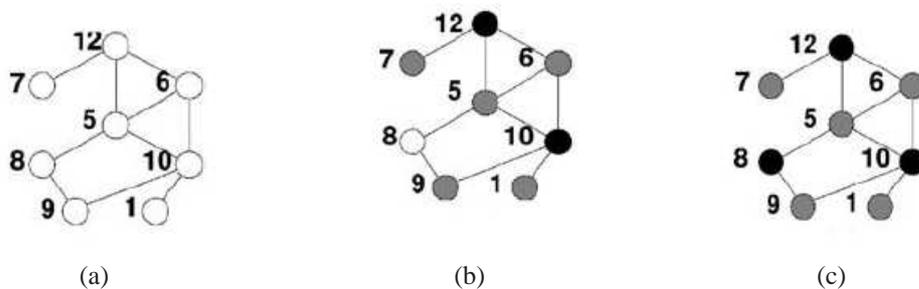


FIG. 6.7 – Exemple d'un processus de décimation [LALLIC03].

2. La deuxième approche est celle développée par KROPATSCHEK [KROPAT95] utilisant un noyau de contraction noté N pour établir le graphe d'un niveau $k + 1$ et donc une

pyramide de graphes. Le lecteur pourra, s'il le désire, obtenir de plus amples informations sur ce sujet dans [KROPAT99]. Pour illustrer ce principe, nous reprenons les deux figures 6.8 et 6.9 présentées dans [KROPAT95] montrant respectivement la construction d'un graphe par un noyau de contraction, ainsi qu'en allant un peu plus loin dans le processus, une pyramide de graphes. Nous partons d'une image présentant différentes régions et construisons le graphe initial G_0 qui lui est lié où chaque noeud est représenté par la couleur de la région correspondante (c'est-à-dire dans notre exemple, noir, gris ou blanc). Il s'agit ensuite de définir un noyau de contraction noté $N(k, k + 1)$ correspondant à un sous graphe où l'on décide quelle information doit survivre au niveau supérieur (i.e. noeuds survivants de couleur noire) et quelle information ne doit pas survivre (noeuds non-survivants de couleur blanche). A la première itération, le noyau de contraction est noté $N_{0,1}$ représentant ainsi le noyau de contraction pour le passage du niveau initial 0 de la hiérarchie au niveau strictement supérieur 1. Le critère de sélection peut être comme c'est le cas ici la contraction des arêtes connectant des composants de même niveau de gris. L'étape suivante consiste à exécuter la contraction du graphe dual puis sa simplification afin de construire le graphe de niveau supérieur $G(k + 1)$ et donc ici G_1 . Ce processus itératif de construction de pyramide de graphes est stoppé lorsque nous atteignons le dernier niveau de la pyramide.

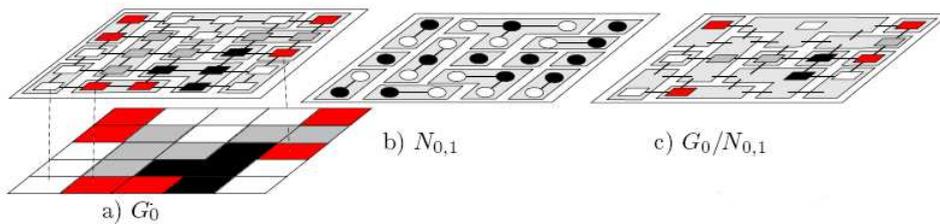


FIG. 6.8 – Exemple de graphe et d'un noyau de contraction ((a) : graphe G_0 , (b) : noyau de contraction $N_{0,1}$, (c) : contraction des arêtes $G_0/N_{0,1}$) [KROPAT95].

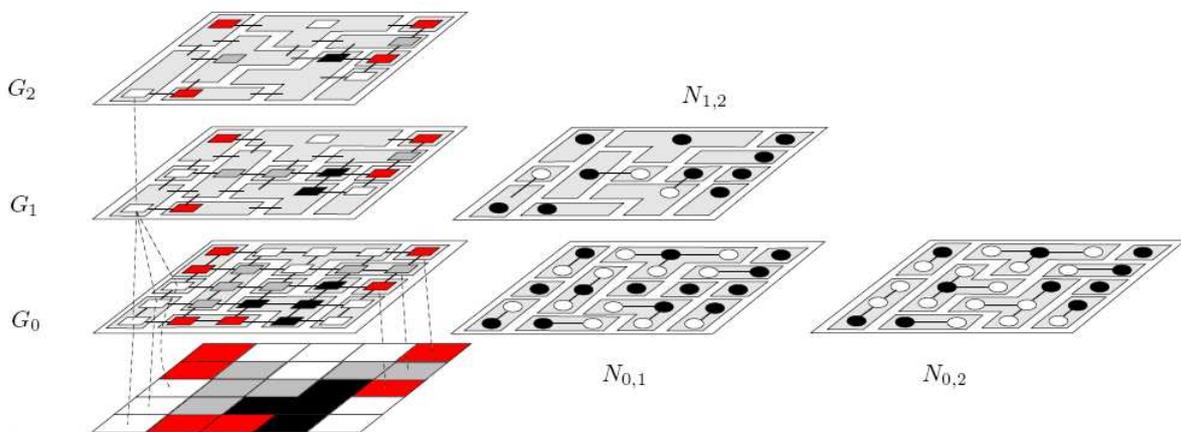


FIG. 6.9 – Pyramide de graphe avec noyau de contraction [KROPAT95].

6.1.2.4 Cartes combinatoires

Les cartes combinatoires font également partie des modèles de représentation par graphes. La définition d'une carte combinatoire diffère de celle que nous avons pu employer précédemment pour les graphes et est donnée sous la forme suivante : $G = (D, \sigma, \alpha)$, où D représente la décomposition de chaque arête en deux demi-arêtes appelées aussi brins, α code les arêtes et σ code les noeuds ou sommets. Les cartes combinatoires présentent de nombreux avantages par rapport aux pyramides classiques comme : l'existence d'une arête pour chaque frontière entre région, l'ordonnancement des brins autour des noeuds et des sommets, le codage implicite du graphe dual ainsi que des relations d'inclusions et d'adjacences, la possibilité de ne pas coder tous les niveaux de la pyramide sans pour autant perdre d'information. La figure 6.10 illustre pour un exemple donné une carte combinatoire et son graphe dual. Nous retrouvons dans la définition de la carte combinatoire $D = \{-6, \dots, -1, 1, \dots, 6\}$, $\alpha = \{(1, -1), (2, -2), (3, -3), (4, -4), (5, -5), (6, -6)\}$ et $\sigma = \{(1, 3, 2), (-3, 4, 5), (-4, 6, -5), (-1, -2, -6)\}$. La définition du graphe dual est donnée par $G^- = (D, \varphi = \sigma \circ \alpha, \alpha)$ avec $\varphi = \{(1, -2), (-1, 3, 4, 6), (-6, -5, -3, 2), (-4, 5)\}$. Le lecteur intéressé par cette famille de pyramides irrégulières pourra trouver de plus amples informations dans les travaux de BRUN ET AL. [BRUN00, BRUN02, BRUN03].

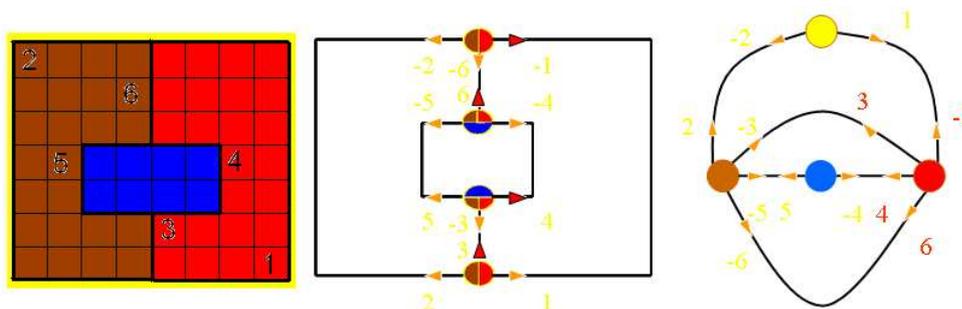


FIG. 6.10 – Exemple d'une carte combinatoire et de son graphe dual.

6.2 Méthodes morphologiques

Comme nous avons pu l'introduire dans le chapitre 3, l'emploi de la couleur en segmentation d'images est devenu très populaire. Des méthodes comme la classification à partir d'histogramme 1D, 2D, 3D, la classification par clustering, la croissance de régions, de coopération régions/contours ont vu le jour il y a plusieurs années et donnent de façon générale des résultats satisfaisants. Mais les méthodes de segmentation hiérarchique apportent une autre dimension à la segmentation d'images couleur.

En traitement d'images, une image I est considérée dans la plupart des cas comme étant un ensemble de pixels : $I = \{p_1, p_2, \dots, p_n\}$. Lorsque nous parlons d'image segmentée, nous faisons référence à une image divisée en régions disjointes selon un critère donné où chaque région R est un sous-ensemble de pixels connexes de l'image constituée de $|R|$ pixels répondant à un même critère d'homogénéité. Mais cette même image segmentée se trouve être le résultat d'un algorithme de segmentation et donc une partition du

domaine de l'image. Avant de décrire différentes méthodes de segmentation hiérarchique, nous allons reprendre la définition de la notion de connexion et de partition.

La notion de connexion, d'un point de vue mathématique, revient à dire que si l'on considère une famille d'ensembles connexes possédant au moins un point en commun, alors leur union est elle aussi connexe. Ce qui peut être traduit sous la forme suivante : $\{A_i \text{ connexes}\}$ et $\{\cap A_i \neq \emptyset\} : \{\cup A_i \text{ connexes}\}$. Mais cette définition d'un point de vue ensembliste n'est pas directement utilisable en traitement d'images. D'autres critiques lui ayant été faites, SERRA [SERRA88] a établi une nouvelle notion de connexion que nous avons reprise ci-dessous :

Définition (Connexion) Soit un espace arbitraire noté E . On appelle une classe connexe ou connexion C toute famille dans $P(E)$ telle que :

- $\emptyset \in C$ et quel que soit un élément ponctuel de $P(E)$ noté $x \in E, \{x\} \in C$,
- pour toute famille $\{C_i\}$ dans $C, \cap C_i \neq \emptyset$ entraîne $\cup C_i \in C$

Définition (Partition) Une partition P est un ensemble de composantes connexes ou régions $P = \{R_1, R_2, \dots, R_k\}$ tel que : l'union des régions de la partition donne l'ensemble de départ : $I = \bigcup_{i=1}^k R_i$, les régions ont une intersection nulle : $\forall i, j, i \neq j, R_i \cap R_j = \emptyset$

Différents algorithmes existants, que nous citerons un peu plus loin, peuvent être utilisés pour segmenter une image et donc créer ce que nous venons d'appeler une partition. Mais ces mêmes algorithmes peuvent également définir, en jouant sur leurs paramètres, un empilement de partitions de niveaux croissants appelé hiérarchie de partitions. Nous comprendrons qu'il est alors important de définir une relation d'ordre entre deux partitions : une partition P est incluse dans une partition Q si toute région R_j^P est incluse dans une région R_i^Q . Ceci nous amène alors à définir une hiérarchie de partitions emboîtées d'une image. Soit H un ensemble de partitions associées à une image, H forme une hiérarchie de partitions s'il est possible d'établir un ordre d'inclusion parmi toute paire d'éléments de l'ensemble H . Deux régions quelconques appartenant à des partitions différentes de la hiérarchie sont soit disjointes soit incluses l'une dans l'autre.

Définition (hiérarchie de partitions emboîtées) Une hiérarchie de partitions emboîtées d'une image est un ensemble de partitions $H = \{P_1, P_2, \dots, P_l\}$ tel que les régions de la partition $P_i = \{R_1^i, R_2^i, \dots, R_k^i\}$ sont incluses dans les régions de la partition $P_j = \{R_1^j, R_2^j, \dots, R_{k'}^j\}$ avec $j > i, k' > k$ et $R_m^i \subseteq R_p^j$ ou $R_m^i \cap R_p^j = \emptyset$

La notation généralement utilisée consiste à appeler P_i le niveau i de la hiérarchie. P_0 représente le niveau inférieur de la hiérarchie et la partition la plus fine d'où son appellation « partition fine ». P_l constitue quant à lui le niveau supérieur de la hiérarchie et la partition la plus grossière. D'après la définition même de la hiérarchie de partitions emboîtées, les régions des niveaux inférieurs étant incluses dans les régions des niveaux supérieurs, une partition de niveau $i + 1$ peut être obtenue par une fusion de plusieurs régions de niveau i .

En morphologie mathématique, le fait d'avoir un ordre entre les partitions implique que la hiérarchie de partitions forme un treillis complet. Les principaux critères morphologiques permettant de définir une hiérarchie de partitions sont basés sur la notion

de connexion. Cette notion de connexion réside dans la définition d'un critère puisqu'une image est segmentée en zones au regard d'un critère donné. Nous reprenons ici un exemple donné dans [SERRA03] : on segmente une image I en zones plates et connexes lorsque l'on crée la partition P_i telle que pour tout x , la région $R \in P_i$ avec $x \in R$ est la plus grande composante connexe contenant le point x et sur laquelle l'image I est constante est égale à x . Quel que soit le critère de connexion choisi, il y a toujours une manière de partitionner une image en zones qui vérifient ce critère. Les zones plates et la Ligne de Partage des Eaux que nous allons présenter ci-dessous sont les principales connexions de segmentation.

6.2.1 Zone plate et quasi-plate

Les zones plates (« flat zones ») d'une image I sont les composantes connexes ayant une valeur constante ce qui constitue, comme nous venons de l'introduire ci-dessus, un critère connectif de segmentation. Elles furent introduites par SALEMBIER ET SERRA [SALEMB92, SALEMB95].

Définition (Zone plate) Deux points p et q appartiennent à la même zone plate d'une image I ssi il existe un chemin connexe (p_1, p_2, \dots, p_n) entre ces deux points tel que $p_1 = p$ et $p_n = q$ et pour tout $i : I(p_i) = I(p_{i+1})$

L'utilisation brute d'une image en zones plates n'est pas très intéressante en soi puisque nous sommes face à une image très sur-segmentée. Une simplification au préalable de l'image où une fusion selon un certain critère de zones plates *a posteriori* permet de réduire le nombre de régions de l'image afin d'être utilisées par exemple comme marqueurs pour la Ligne de Partage des Eaux. Pour palier cet inconvénient MEYER [MEYER98] a proposé d'étendre le concept de zone plate à celui de zone quasi-plate.

Définition (Zone quasi-plate) Deux points p et q appartiennent à la même zone quasi-plate d'une image I ssi il existe un chemin connexe (p_1, p_2, \dots, p_n) entre ces deux points tel que $p_1 = p$ et $p_n = q$ et pour tout $i : \|I(p_i) - I(p_{i+1})\| \leq \lambda$

avec $\|\cdot\|$ représentant une norme L_2 et λ le critère de seuil. Notons bien évidemment qu'un critère de seuil $\lambda = 0$ revient à considérer une zone plate au sens strict du terme et qu'une utilisation croissante de ce critère permet de définir une hiérarchie de partitions. Cette dernière remarque est illustrée sur la figure 6.11 où nous retrouvons sur la figure 6.11(a) les zones plates de l'image ($\lambda = 0$), de la figure 6.11(b) à la figure 6.11(d) les zones quasi-plates de l'image ($\lambda = 5$, $\lambda = 10$, $\lambda = 20$), de la figure 6.11(e) à la figure 6.11(d) les mosaïques respectives des zones plates et quasi-plates de l'image ($\lambda = 0$, $\lambda = 5$, $\lambda = 10$, $\lambda = 20$). Le nombre de régions diminue au fur et à mesure que l'on progresse dans la hiérarchie (respectivement 87606, 39571, 8250, 1765 régions) pour arriver vers une image où la perte d'information est très importante, il est alors nécessaire d'être attentif sur la détermination du critère de seuil afin de simplifier l'image initiale mais sans trop la dégrader. Nous proposerons plus loin dans ce manuscrit une méthode permettant de définir quel est le meilleur niveau de la hiérarchie.

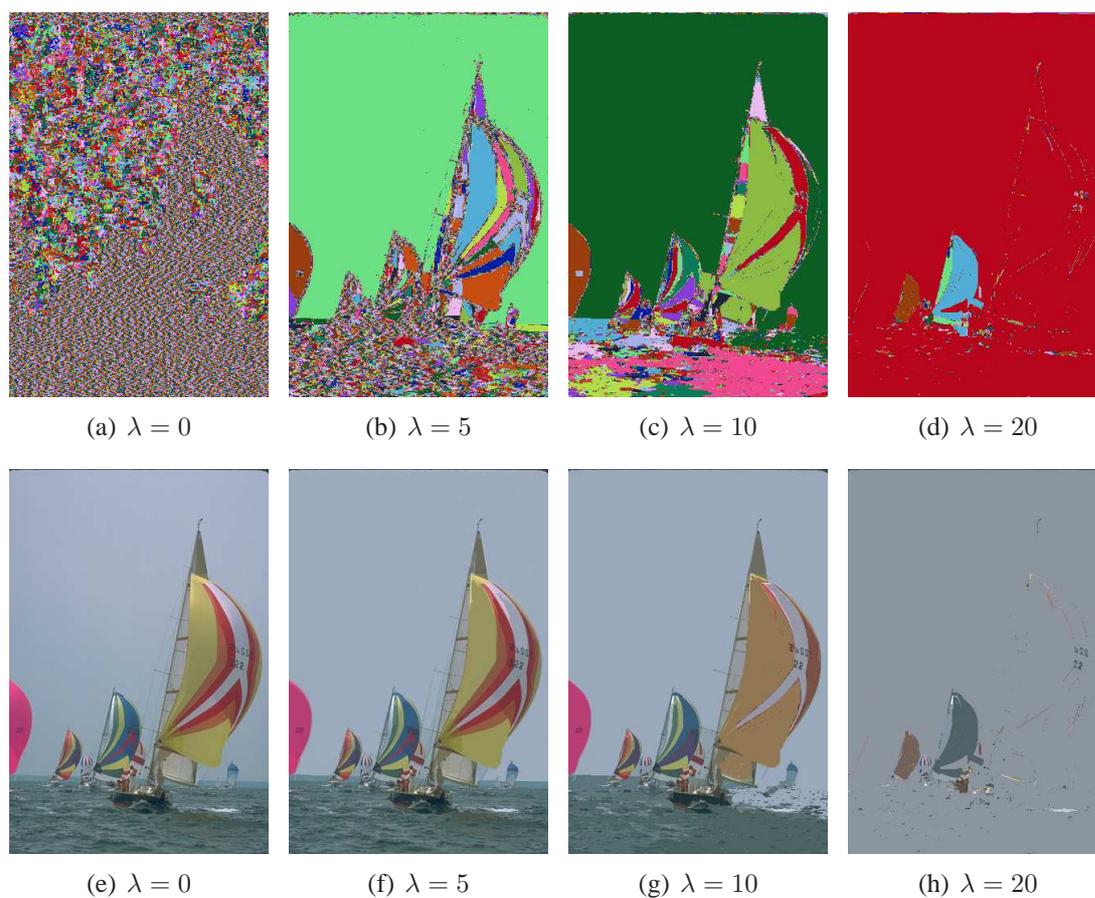


FIG. 6.11 – Zones plates et quasi-plates d'une image ((a) les zones plates puis (b-d) quasi-plates de l'image et (e-h) leurs images mosaïques respectives).

6.2.2 Connexion par sauts

Les connexions par sauts (« jump connection ») instaurées par SERRA [SERRA00] font partie des méthodes de segmentation par critère connectif. Cette méthode de croissance de régions est basée sur des variations d'amplitudes dont les origines correspondent aux minima d'une image I .

Définition (Connexion par sauts) Considérons pour une valeur d'amplitude λ donnée, la composante connexe qui contient un minimum η d'une image I et dont les points z accusent un dénivelé $(I(z)-\eta)$ au dessus de η tel que $0 < (I(z)-\eta) \leq \lambda$, $A(\eta) = \{z : z \in E, 0 < (I(z)-\eta) \leq \lambda\}$. Posons $P_{\lambda,\eta}$ la partition composée de $A(\eta)$ plus les classes ponctuelles sur $E \setminus A(\eta)$. Prenons le supremum P_λ de toutes les partitions $P_{\lambda,\eta}$ associées à tous les minima de la fonction. Nous réitérons ensuite le processus sur l'ensemble $E \setminus \cup A(\eta)$.

Une hiérarchie de partitions produite par cette méthode est illustrée sur la figure 6.12. L'utilisation de cette méthode nécessitant de travailler sur une image en niveaux de gris, nous avons dans cet exemple décomposé l'image couleur initiale représentée sur la figure 6.12(e) en trois composantes afin de pouvoir travailler sur l'une d'entre elles, par exemple la composante « Rouge » de l'espace RVB représentée ici sur la figure 6.12(a). De la figure 6.12(b) à la figure 6.12(d), nous trouvons les images de connexion par sauts aux valeurs d'amplitude $\lambda = 5$, $\lambda = 20$, $\lambda = 50$ et de la figure 6.12(f) à la figure 6.12(h), les images mosaïques respectives.

L'utilisation intrinsèque de méthodes basées sur des critères connectifs tels que les zones plates, quasi-plates ou les connexions par sauts apportent des résultats intéressants. Nous pouvons citer quelques travaux comme ceux de CRESPO, GOMILA, ANGULO ET ZANOQUERA [CRESPO94, GOMILA01, ANGULO03A, ZANOQUERA01] qui élargissent le concept de segmentation par critère connectif à celui des images couleur. Nous pouvons retrouver par exemple dans les travaux de CRESPO ET SCHAFER [CRESPO94] les zones plates couleurs définies comme étant l'intersection des zones plates les plus importantes sur chacune des composantes de l'espace couleur. ZANOQUERA [ZANOQUERA01] emploie une distance vectorielle pour calculer le critère de seuil relatif à la définition des zones quasi-plates.

6.2.3 Ligne de Partage des Eaux

La Ligne de Partage des Eaux est un opérateur de croissance de régions définissant une connexion par cheminement basée sur le gradient morphologique d'une image. Les germes de la LPE étant les minima du gradient morphologique. C'est une méthode ayant fait ses preuves et très utilisée dans le domaine de la segmentation d'images mais l'inconvénient majeur réside dans l'obtention d'une sur segmentation due à un nombre important de minima. Une alternative pour pallier cet inconvénient consiste à ne plus utiliser les minima comme germes de LPE mais des marqueurs correspondant aux régions à segmenter comme nous avons pu le faire dans le chapitre intitulé « Segmentation par classification pixellaire » en utilisant des marqueurs cytoplasmique et nucléaire pour segmenter nos objets cellulaires.

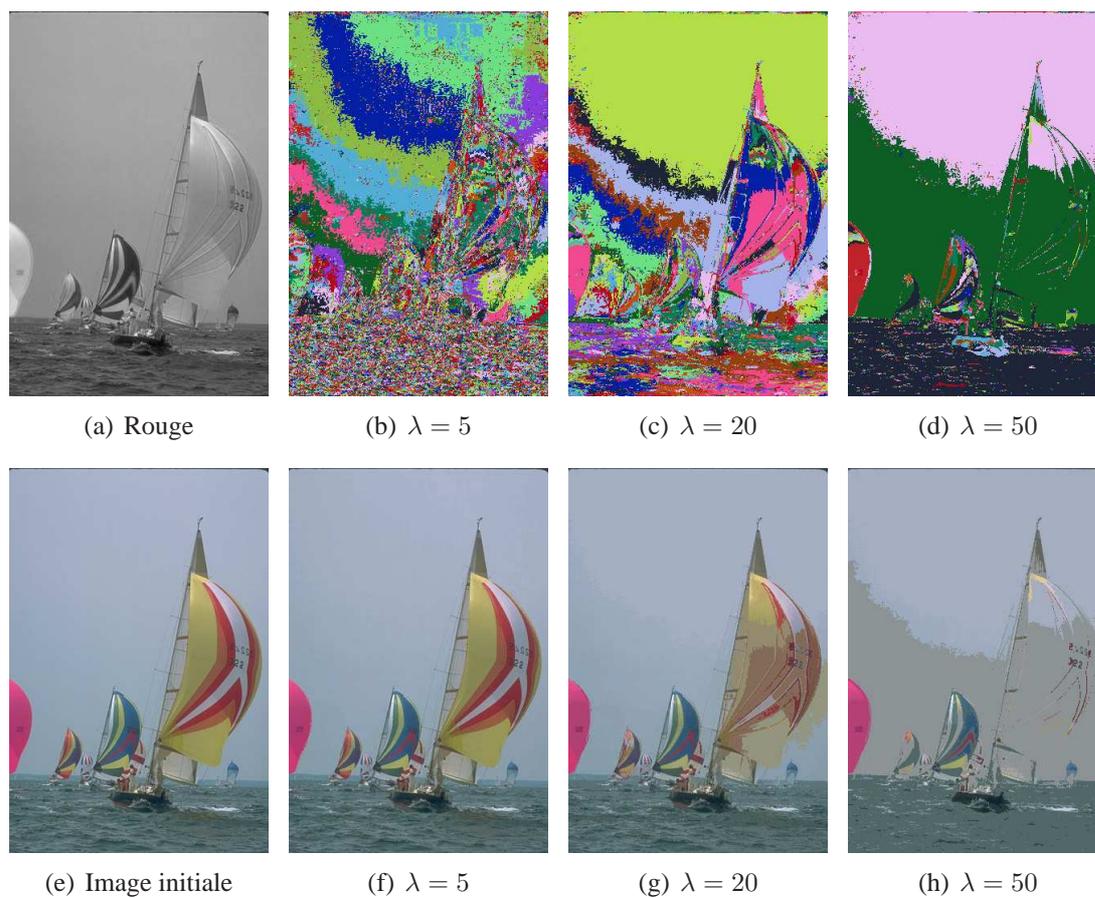


FIG. 6.12 – (a) Connexion par saut de la composante rouge d’une image ((b-d) les connexions par sauts aux valeurs d’amplitude λ , (e) l’image couleur initiale, (f-h) images mosaïques des différents connexions par sauts aux valeurs d’amplitude λ).

L'arrivée de techniques de segmentation hiérarchiques a probablement engendré l'intérêt d'une Ligne de partage des Eaux hiérarchique non-paramétrique. L'algorithme des cascades de la LPE (« waterfall ») que l'on peut retrouver dans [BEUCHE94, ANGULO03B] permet de construire cette LPE hiérarchique non paramétrique qui procède à une fusion des bassins versants. Il est ainsi basé sur la reconstruction de la fonction gradient de l'image mosaïque avec sa LPE. En réitérant un certain nombre de fois cette procédure de sorte à obtenir une cascade de LPE, nous obtenons une hiérarchie de partitions.

La figure 6.13 illustre une hiérarchie de partitions obtenue par l'algorithme de waterfall. L'image obtenue au niveau le plus bas de la hiérarchie, c'est-à-dire au niveau 0, contient 6215 régions et celle qui représente le niveau le plus élevé, correspondant alors au niveau 10 dans notre exemple, en contient seulement 38. Néanmoins, nous pouvons remarquer que malgré cette forte diminution du nombre de régions (environ égale à un facteur de 1/163), il nous est encore possible de reconnaître les principaux objets de l'image.

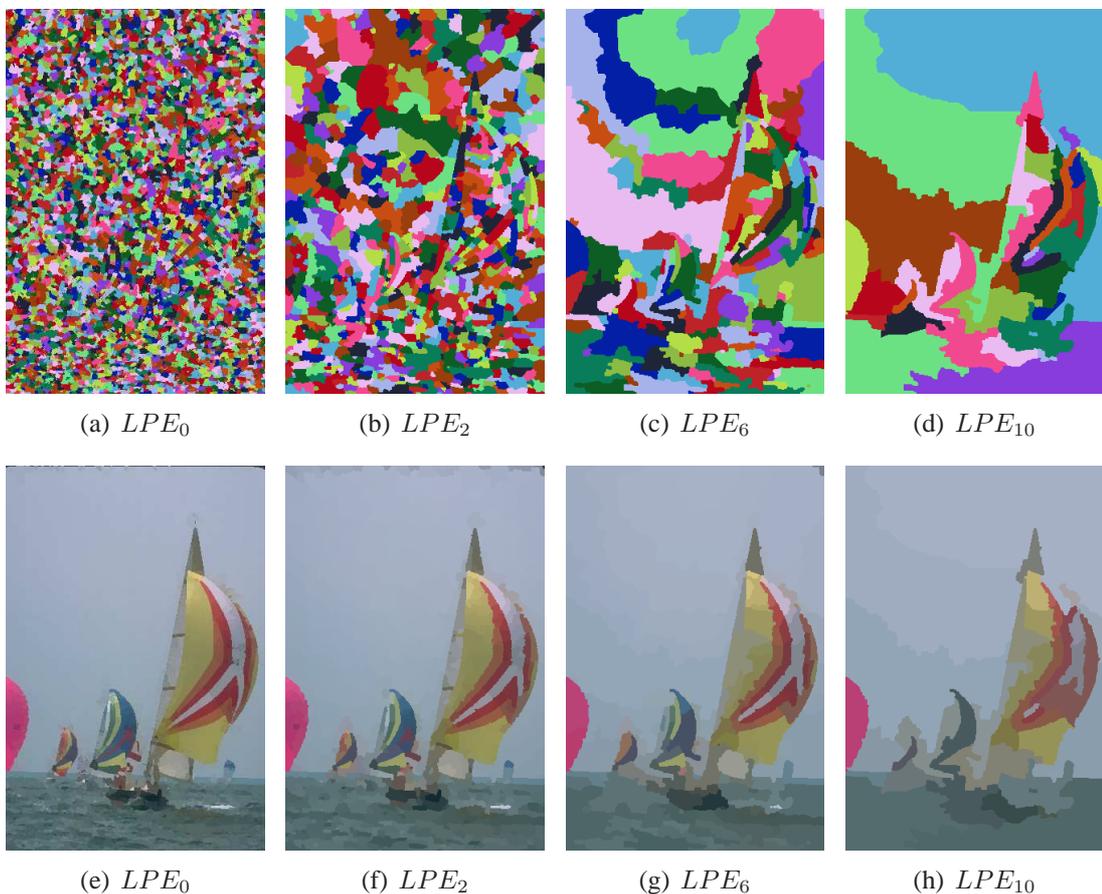


FIG. 6.13 – Hiérarchie de partitions par l'algorithme de waterfall ((a-d) l'image découpée en régions par l'algorithme de waterfall, (e-h) l'image mosaïque respective).

L'application d'une LPE aux images couleur a amené de nombreuses discussions sur le calcul d'une fonction gradient. En effet l'approche couramment utilisée pour la LPE couleur consiste à calculer une fonction gradient de l'image couleur originale. Divers travaux traitent de ce sujet comme ceux de MEYER dans [MEYER90] qui consiste à calculer une fonction gradient sur chacune des composantes de l'espace couleur, à effectuer une LPE à partir de chaque gradient, puis à combiner les trois LPE obtenues séparément en une LPE

résultante. DEMARTHY ET BEUCHER [DEMART98] définissent un gradient couleur dans une version de l'espace HSL . D'autres approches [SHAFAR97, RISSON01] consistent à calculer un gradient vectoriel dans un espace de représentation couleur donné et d'y appliquer une LPE dessus.

La combinaison de ces méthodes de segmentation par critères connectifs avec une Ligne de Partage des Eaux couleur a été récemment étudiée. GOMILA [GOMILA01] utilise une LPE calculée sur un gradient couleur résultant de la somme des trois gradients obtenus sur chaque composante d'un espace couleur d'une image mosaïque de zones plates.

VANHAMEL AND AL. [VANHAM00] présentent une Ligne de Partage des Eaux calculée sur le gradient de DiZenko comme pré-segmentation et un schéma de fusion hiérarchique espace-échelle utilisé en aval pour réduire la sur-segmentation produite par la Ligne de Partage des Eaux.

SHAFARENKO ET AL. [SHAFAR97] utilisent un algorithme de segmentation hiérarchique par waterfall sur une image gradient dans l'espace de représentation couleur LUV et estimé avec la distance euclidienne. Un critère de terminaison est également appliqué à un processus de fusion de régions. Il est basé sur la topologie d'images texturées aléatoirement.

6.2.4 Fusion de régions dans un treillis

Les méthodes présentées précédemment telles que les zones plates ou quasi-plates, les connexions par sauts voire même la Ligne de Partage des Eaux ont tendance à fournir des images qui dans le cadre de la segmentation d'images, et prises de façon brute, ne sont pas très intéressantes car généralement sur segmentées. Ce problème peut être réduit si l'on prend soin de définir de façon la plus juste possible les différents paramètres de la méthode. Nous pensons bien évidemment au critère de seuil pour les zones quasi-plates et à la valeur d'amplitude pour les connexions par sauts qui peuvent être augmentés afin de réduire le nombre de régions de l'image et par voie de conséquence augmenter leur taille. Néanmoins, cela reste dans la plupart des cas insuffisant pour obtenir une image qui ne soit pas sur-segmentée.

C'est pourquoi on fait généralement appel à des techniques de fusion de régions [TRÉMEA00, ANGULO03B, ZHU96, GUIGUE03B, ZANOBU01, NOCK01, NOCK04, SALEMB97, GRECU00, LEZORA03C, MAKROG01, MAKROG02, HARIS98, ARBELA04] dont nous présentons l'approche générale ci-dessous : un algorithme de fusion de régions a pour but de fusionner certaines régions de l'image par suppression de certains noeuds et arrêtes du Graphe d'Adjacence de Régions. Cet algorithme nécessite de définir trois principes, à savoir l'ordre de fusion, le critère de fusion et le modèle de région :

- l'ordre de fusion représente l'ordre dans lequel seront analysés les liens afin de savoir s'ils devront être supprimés ou non. Cet ordre noté $O(R_i, R_j)$ est défini par une fonction qui se trouve être généralement une mesure de similarité associée à chaque paire de régions voisines R_i et R_j et fournissant une valeur réelle ;

- à chaque lien traité, le critère de fusion noté $C(R_i, R_j)$ décide si la fusion de deux régions voisines R_i et R_j doit être effectuée ou non. Ce critère de fusion peut par exemple être le nombre minimum de régions ou encore un critère de qualité, de surface ;
- le modèle de région noté $M(R)$ consiste à définir la façon dont sera représentée la fusion de deux régions voisines. Cela peut être le niveau de gris moyen ou la couleur moyenne de la région.

Nous illustrons par la figure 6.14 la simplification d'un Graphe d'Adjacence de Régions relatant la fusion de deux régions. Sur cet exemple, les régions 4 et 7 sont fusionnées pour former une seule région notée 4' ce qui a bien évidemment entraîné une suppression ou ré-actualisation des arêtes notées $C(1, 7)$, $C(2, 7)$, $C(3, 7)$, $C(4, 7)$, $C(5, 7)$, $C(6, 7)$ et $C(1, 4)$, $C(4, 5)$, $C(4, 6)$ en $C(1, 4')$, $C(2, 4')$, $C(3, 4')$, $C(4', 5)$, $C(4', 6)$.

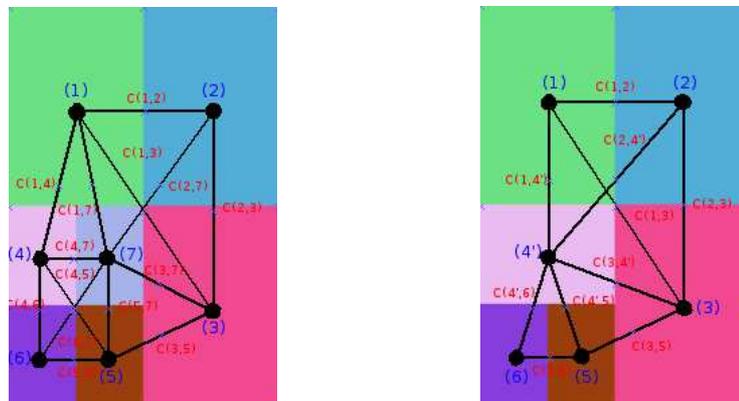


FIG. 6.14 – Simplification du Graphe d'Adjacence de Régions (à gauche : le RAG initial et à droite : le RAG obtenu après fusion de deux régions).

Les points clés de l'implémentation algorithmique sont d'une part une file d'attente hiérarchique et d'autre part la mise à jour de la structure du Graphe d'Adjacence de Régions. La première étape consiste à initialiser le Graphe d'Adjacence de Régions et la file d'attente hiérarchique. Chaque région de l'image est initialisée à partir du calcul de son modèle $M(R)$. Chaque arête se voit ensuite attribuer un ordre de fusion $O(R_i, R_j)$ afin d'être insérée à un endroit précis dans la file d'attente hiérarchique. Le processus itératif de fusion de régions peut alors commencer. L'arête de la file hiérarchique ayant la plus faible valuation est extraite de sorte à déterminer (selon les conditions présentées auparavant) si les noeuds correspondant doivent être fusionnés ou non. Dans la négative, l'arête est alors totalement supprimée de la file d'attente et le processus procède à l'extraction de la prochaine arête ayant la plus faible valuation. Dans l'affirmative, l'information relative aux deux régions reliées par l'arête est fusionnée, ce qui a pour conséquence de mettre à jour le modèle de région ainsi que l'ordre de fusion des arêtes voisines en les retirant de la file d'attente hiérarchique, de calculer leurs nouvelles priorités et de les insérer à leur place dans la file. Le processus entier est répété jusqu'à ce qu'il ne reste plus d'arêtes dans la file d'attente hiérarchique ou jusqu'à un critère de terminaison. Une implémentation efficace de la file hiérarchique utilise généralement un arbre binaire équilibré qui permet une gestion efficace de la priorité pour un grand nombre de noeuds et permet en outre des

accès rapides en insertion et suppression.

Pour ces stratégies de fusion, une solution basée sur un arbre binaire de partitions (binary partition tree en anglais) est souvent utilisée. Un arbre binaire de partitions est une représentation structurée des régions présentes dans la partition initiale d'une image donnée. L'arbre se construit de façon ascendante par fusion de deux régions filles et permet ainsi de visualiser l'ensemble des régions obtenues à différents niveaux de la hiérarchie. Il part des multiples régions appartenant à la partition la plus fine pour arriver à une seule région nommée racine de l'arbre. Les grandes régions apparaissent près de la racine tandis que les petites régions correspondent à des détails se trouvent à des niveaux les plus bas. Une feuille de l'arbre correspond à une région de la partition fine initiale.

Un exemple simple de création d'arbre binaire de partitions avec un algorithme de fusion de régions est présenté sur la figure 6.15. L'image initiale de la figure 6.15(a) est découpée en sept régions. Une amorce de fusion deux à deux de régions est présentée sur les figures 6.15(b) à 6.15(d) ainsi que la génération de leur arbre binaire de partitions respectif sur les figures 6.15(e) à 6.15(g). Un deuxième exemple plus complet de génération d'arbre binaire de partitions que l'on peut retrouver dans [TA04] est présenté sur la figure 6.16. L'image initiale présentée sur la figure 6.16(a) est une image couleur représentant trois avions. Une segmentation par quadtree divisant l'image en plusieurs régions est présentée sur la figure 6.16(b) suivie de l'image re-colorisée 6.16(c) à partir de l'image originale et de la carte de segmentation sur la figure 6.16(b). L'arbre binaire de partitions généré est présenté sur la figure 6.16(d). Notons que les noeuds de couleur noire présents sur ce dernier représentent les feuilles de l'arbre et donc les régions présentes sur la carte de segmentation de la figure 6.16(b).

Les techniques de fusion de régions sont généralement utilisées comme outils de segmentation ou de simplification. SALEMBIER ET AL. [SALEMB97] ont présenté une technique de fusion de régions basée sur les trois étapes que sont l'ordre de fusion, le critère de fusion et le modèle de région et que nous allons détailler ci-dessous :

- le modèle de région est défini comme étant la médiane. L'implémentation de la médiane pour la région $R = R_i \cup R_j$ devrait être calculée par rapport aux médianes respectives des R_i et R_j mais SALEMBIER ET AL. ont choisi d'attribuer le modèle de région M_R comme étant le modèle de la plus grande région ou en cas d'égalité des modèles relatifs aux deux régions ;
- l'ordre de fusion peut par exemple être défini par la probabilité d'appartenance de deux régions voisines à un même objet. Un bon compromis entre l'extraction de régions et la conservation des contours peut être obtenu sur des images en niveau de gris en définissant l'ordre de fusion de la manière suivante : $O(R_i, R_j) = N_i(M_{R_i} - M_R)_2 + N_j(M_{R_j} - M_R)_2$. Cette définition peut être étendue à des images couleur en effectuant une combinaison linéaire des ordres de fusion $O(R_i, R_j)$ calculés sur chacune des composantes de l'espace couleur ;
- le critère de fusion $C(R_i, R_j)$ décide, parmi l'ensemble des objets présents dans l'image, quelles régions seront fusionnées. Celui ci est basé sur un opérateur de surface et décide que deux régions doivent être fusionnées si au moins l'une d'entre elles est plus petite qu'un seuil fixé.

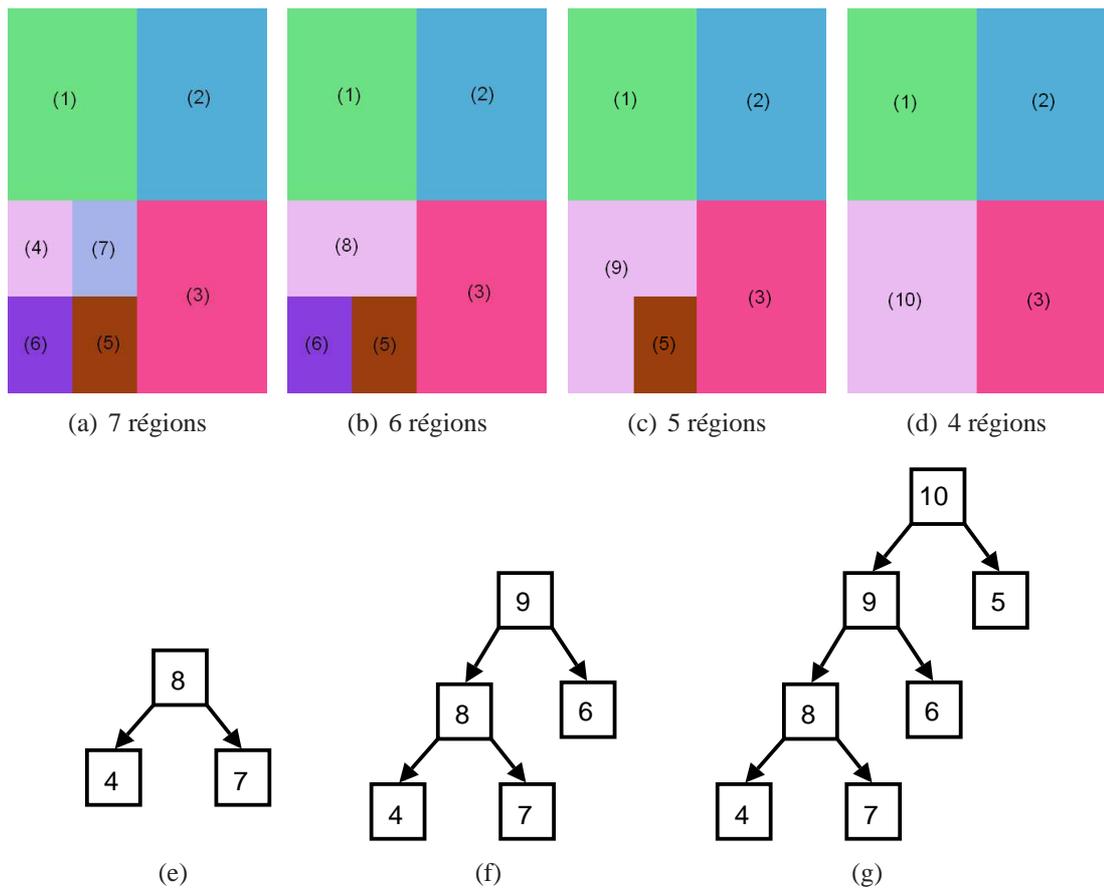


FIG. 6.15 – Exemple de création d'un arbre binaire de partitions avec un algorithme de fusion de régions ((a) l'image initiale découpée en 7 régions, puis (b-d) respectivement cette même image avec une fusion de régions deux à deux, (e-g) suivie de la représentation de ces fusions par un arbre binaire de partitions).

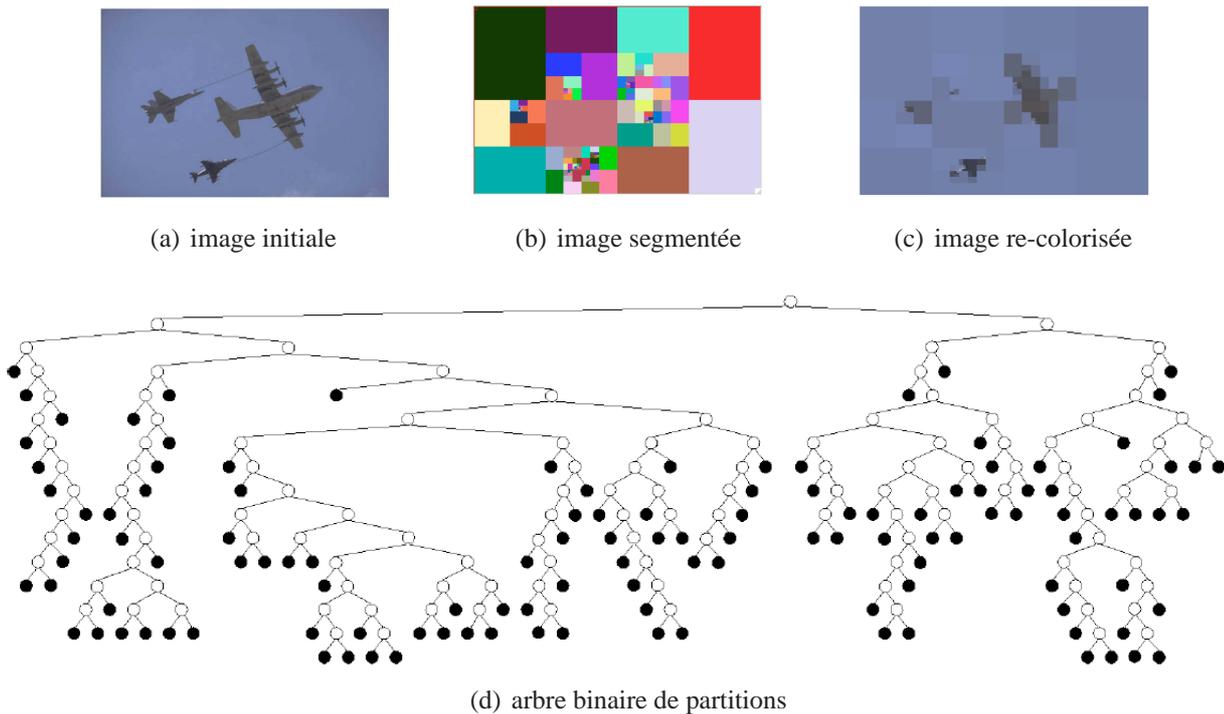


FIG. 6.16 – Exemple d'un arbre binaire de partitions sur une image.

En segmentation d'images, les techniques de fusion de régions sont généralement combinées à un critère de décision définissant l'arrêt du processus de fusion. L'utilisation d'une approche par hiérarchie de partitions permet d'attribuer une segmentation de l'image à chaque niveau de la hiérarchie. Le but de cette technique étant d'obtenir une segmentation de bonne qualité, les derniers niveaux de la hiérarchie ne sont généralement pas utilisables. Mais la difficulté réside dans le fait de savoir quel niveau de la hiérarchie donne la meilleure segmentation. Pour ce faire, une évaluation de la qualité de la segmentation est généralement réalisée à chaque niveau de la hiérarchie afin de définir, soit au fur et à mesure de la construction de cette dernière soit en fin de traitement, quelle segmentation est la plus performante. SALEMBIER ET AL. ont choisi d'utiliser un critère de décision basé sur la mesure du Peak Signal to Noise Ratio (PSNR) entre l'image initiale et l'image produite au niveau k de la hiérarchie ainsi que sur le nombre de régions présentes dans l'image produite.

GRECU ET LAMBERT [GRECU00] proposent une approche de simplification de segmentation d'images couleur basée sur une représentation d'un « graphe attribué » associé à une règle floue. Différents attributs comme la teinte, la saturation, l'intensité, la surface, le périmètre de chaque région, la notion de connexité relatant le périmètre commun normalisé entre deux régions voisines, etc. sont utilisés et regroupés dans trois catégories de degrés de similarités à savoir des informations de couleur, de géométrie et de connexité. Une règle de décision floue donnée permet alors d'attribuer à chacune de ces trois catégories de degré de similarité une valeur floue (petite, moyenne, grande). Un degré de similarité global est ensuite défini comme étant la combinaison des trois degrés de similarité précédents et une valeur numérique lui est attribué. La simplification du graphe est alors aisée. Lorsque

le degré de similarité associé à une arête est plus important qu'un seuil fixé, l'arête est supprimée et les deux noeuds qui y étaient liés sont fusionnés. Le processus itératif est réitéré jusqu'à ce qu'il n'y ait plus de degré de similarité qui soit supérieur au seuil prédéfini.

LEZORAY ET CARDOT [LEZORA03C] proposent dans le cadre de la segmentation d'images couleur, une nouvelle technique de simplification de Graphe d'Adjacence de Régions basée sur la fusion de régions deux à deux et ce jusqu'à la stabilisation d'un critère définissant la pertinence de la segmentation obtenue. Dans un premier temps, plusieurs histogrammes $2D$ sont partitionnés et les cartes de régions correspondantes sont fusionnées fournissant ainsi une pré-segmentation de l'image nécessaire à la construction du Graphe d'Adjacence de Régions initial. Dans une deuxième phase le Graphe d'Adjacence de Régions est simplifié et donc certaines régions sont fusionnées pour donner naissance à une nouvelle carte de régions :

- le modèle de la région R correspondant à la fusion des régions R_i et R_j est la somme du modèle des deux régions : $M(R) = M(R_i \cup R_j) = M(R_i) + M(R_j)$. Chaque région R dispose d'un modèle associé $M(R)$ composé de quatre valeurs (r, g, b, n) où (r, g, b) correspondent respectivement à la somme des composantes couleurs R, G, B de tous les pixels appartenant à la région R et n le nombre de pixels de la région R ;
- l'ordre de fusion est basé sur la mesure de similarité entre deux régions adjacentes. Il est défini comme $O(R_i, R_j) = N_i \|M(R_i) - M(R)\|_2 + N_j \|M(R_j) - M(R)\|_2$ où N_i et N_j représentent l'aire respective des régions R_i et R_j , et $\|\cdot\|_2$ une norme L_2 ;
- un nouveau critère de terminaison de fusion est proposé dans cette approche. Celui-ci est basé sur une mesure de qualité de segmentation effectuée par la méthode de LIU ET BORSSOTI, méthode que nous avons détaillée dans un chapitre précédent. La méthode d'évaluation de la qualité de segmentation est alors définie comme suit et sert de critère de terminaison (à stabilisation) :

$$F(G, I) = \frac{\sqrt{\theta_t(G)}}{1000 \times h \times w} \left(\sum_{i=1}^{\theta_t(G)} \frac{e_i^2}{1 + \log(N_i)} + \sum_{j=1}^{\theta_t(G)} \sum_{k>j} E_{j,k} \right)$$

où G représente le graphe, $\theta_t(G)$ le nombre de noeuds du graphe à une itération t donnée. I l'image couleur initiale, $h \times w$ la taille de l'image, N_i le nombre de pixels de la région i , $E_{j,k}$ la longueur de l'arête entre les régions j et k , et où e_i^2 est calculé de la façon suivante : $e_{R_i \cup R_j}^2 = \frac{N_{R_i} e_{R_i}^2 + N_{R_j} e_{R_j}^2}{N_{R_i \cup R_j}}$.

Pour finir, les contours de ces régions sont affinés par l'utilisation d'une Ligne de Partage des Eaux couleur combinant les propriétés globales et locales de l'image.

MAKROGIANNIS ET AL. [MAKROG01] proposent une méthode de segmentation hybride de division/fusion combinant des informations de contours et de régions pour fusionner certaines régions adjacentes produites lors d'une première étape de segmentation par LPE. Une nouvelle approche utilisant ce que les auteurs appellent un « Most Coherent Neighbor Graph (MCNG) » est proposée pour simplifier la structure d'un Graphe d'Adjacence de Régions et accélérer le processus de fusion d'une segmentation automatique.

Un changement d'espace de représentation couleur (de RGB à YC_bC_r) favorisant l'intensité et les couleurs des contours est également utilisé dans cette procédure. La fonction de coût dans le processus de fusion se trouve être le résultat du produit de différents paramètres à savoir : l'entropie relative, la « dynamique des contours », la « Common Boundary Corner » et la « Common Boundary Sharpness ». Afin de pouvoir produire une segmentation automatique, un critère de terminaison utilisant l'information du « Most Coherent Neighbor Graph (MCNG) » est défini afin de ne pas fusionner certaines régions de l'image présentant une forte dissimilarité.

6.3 Conclusion

Dans ce chapitre, nous avons présenté les différents modèles de structuration d'une image. Nous avons alors introduit les pyramides régulières, irrégulières, l'arbre quaternaire, le graphe de frontières de régions et le graphe d'adjacence de régions (RAG). Nous avons développé le principe de construction d'une pyramide de graphes que nous retrouverons dans le chapitre suivant. Nous nous sommes ensuite attaché à la morphologie mathématique couleur en présentant différentes méthodes de création de hiérarchie de partitions que nous comparerons dans le chapitre 7, telles que les zones plates ou quasi-plates, les connexions par sauts et une ligne de partage des eaux hiérarchique non paramétrique appelée aussi « waterfall ». Enfin, nous avons rappelé le principe des techniques de fusion de régions dans un treillis permettant de réduire par exemple les sur-segmentations produites par les méthodes précédentes.

DE NOUVELLES APPROCHES HIÉRARCHIQUES

Sommaire

7.1	Zones homogènes	120
7.2	Morphologie mathématique couleur	124
7.3	Simplification et segmentation d'image par lissage non linéaire d'un graphe et fusion de régions	133
7.4	Evaluation d'une hiérarchie de partitions	140
7.5	Simplification d'une partition par fusion de régions	150
7.6	Berkeley Segmentation Dataset and Benchmark	153
7.7	Conclusion	155

NOUS avons traité dans la première partie de ce manuscrit des méthodes de segmentation d'images couleur que nous pouvons qualifier de bas-niveau car celles-ci travaillent au niveau du pixel. Dans cette deuxième partie, nous nous intéressons à un niveau supérieur qui est celui de la région. Les méthodes de simplification et de segmentation basées sur des techniques « espace-échelle » font partie de cette catégorie. L'augmentation de leurs paramètres permet de simplifier davantage l'image, mais ne respecte pas le principe d'inclusion entre deux niveaux successifs d'une hiérarchie, rendant ainsi la segmentation de l'image faussée. Pour pallier cet inconvénient, il est nécessaire de recalculer une partition obtenue au niveau « i » soit par rapport au niveau inférieur « $i-1$ » [DOMBRE03], soit par rapport au niveau initial « 0 ». Dans ce chapitre, nous proposons des méthodes de création de hiérarchie de partitions basées sur une approche par graphe respectant ce principe d'inclusion entre deux niveaux successifs. Pour ce faire, nous proposons tout d'abord une méthode que nous nommerons « zones homogènes » permettant de générer une partition fine servant de base dans la construction d'une hiérarchie de partitions. Nous proposons ensuite une redéfinition d'une opération de morphologie mathématique qui est la Ligne de Partage des Eaux permettant elle aussi de créer une hiérarchie de partitions. Celle-ci étant basée sur la définition d'un gradient morphologique couleur, il se pose un problème pour la définition d'un treillis complet. Nous proposons alors une stratégie basée sur une décimation itérative d'un graphe d'adjacence associé à un élément structurant qui permet de pallier ce défaut des approches morphologiques couleur classiques. Nous montrons ensuite une stratégie hiérarchique rapide sur graphe d'adjacence de régions pour la simplification et la segmentation d'images utilisant un schéma de diffusion et de fusion couleur sur graphe. Enfin, afin d'estimer automatiquement la qualité d'une partition obtenue dans le cadre d'une hiérarchie de partitions, une mesure d'énergie est proposée afin de déterminer automatiquement le meilleur niveau d'une hiérarchie.

Cette mesure d'énergie pouvant être utilisée dans le cadre d'une fusion de régions par descente d'énergie.

7.1 Zones homogènes

Après avoir présenté dans le chapitre précédent deux approches de segmentation par critère connectif à savoir les zones plates ou quasi-plates et les connexions par sauts, nous allons maintenant proposer un nouveau critère connectif qui est une variation des connexions par cheminements et des connexions par seuil que nous appellerons les zones homogènes et dont la définition est donnée ci-dessous [LEZORA05].

Définition (Zones homogènes) Deux points p et q appartiennent à une même zone homogène d'une image I ssi $\|I(p) - I(q)\| \leq k \times \lambda(\text{Germe}(p))$, avec $\text{Germe}(p)$ le pixel germe de la région de p et $\lambda(p) = \frac{1}{n_v} \sum_{p_v \in V(p)} \|I(p) - I(p_v)\|$

où $V(p)$ désigne l'ensemble des voisins du point p et n_v le cardinal de cet ensemble. $\|\cdot\|$ est une norme L_2 et k un nombre réel correspondant à la finesse de la partition générée. Initialement, tous les pixels p de l'image sont enfilés dans une file hiérarchique avec pour priorité la valeur de $\lambda(p)$. $\lambda(p)$ étant proche d'une mesure de gradient, les pixels se trouvant dans des zones homogènes (la variation de couleur est faible) seront traités en premier comme germes de région. Chaque région est composée initialement d'un pixel et croît en agrégeant progressivement les pixels adjacents à celle-ci selon la règle précédente. Ceci se traduit par le fait qu'un pixel q est agrégé à une région R si la distance entre un pixel p de R voisin de q est k fois inférieure à l'homogénéité du pixel germe de R . k représente le saut d'homogénéité accepté pour que deux pixels appartiennent à une même région. Les zones homogènes produisent des segmentations dont la finesse décroît avec l'augmentation du paramètre k (la contrainte est relâchée). Une hiérarchie de partitions obtenue pour des valeurs croissantes de k est bien évidemment non stratifiée car cela diminue le nombre de germes initiaux via la relâche de la contrainte d'homogénéité. Les zones homogènes produisent des partitions qui respectent bien les contours des objets et elles sont très bien adaptées à une utilisation dans le cadre de segmentations automatiques. Ceci pour plusieurs raisons : elles ne nécessitent pas de marqueurs, elles fonctionnent sur l'image et non son gradient morphologique, ce qui ne pose donc pas de problème pour l'utilisation de la couleur et ceci quel que soit l'espace couleur utilisé. De plus, contrairement aux zones quasi-plates, les zones homogènes s'adaptent localement au contenu de l'image car le seuil d'appartenance d'un pixel à une région dépend d'un critère local d'homogénéité. Elle préservent également les structures fines qui peuvent être détruites lors du calcul d'un gradient. Différentes finesse de segmentations obtenues par les zones homogènes sont données par la figure 7.1. La variation du paramètre réel k variant de 0.5 à 5 donne des partitions de finesse décroissante et une baisse du nombre de régions : 23127 régions pour $k = 0.5$, 2338 pour $k = 1.5$, 1464 pour $k = 2$ et 700 pour $k = 5$. Nous pouvons d'ores et déjà constater qu'il n'est pas nécessaire d'utiliser des valeurs très élevées du paramètre de finesse k pour obtenir une diminution flagrante du nombre de régions de l'image.

Si l'on désire construire une hiérarchie de partitions de zones homogènes qui soit stratifiée, il faut se contraindre à respecter le principe d'inclusion des régions entre deux niveaux

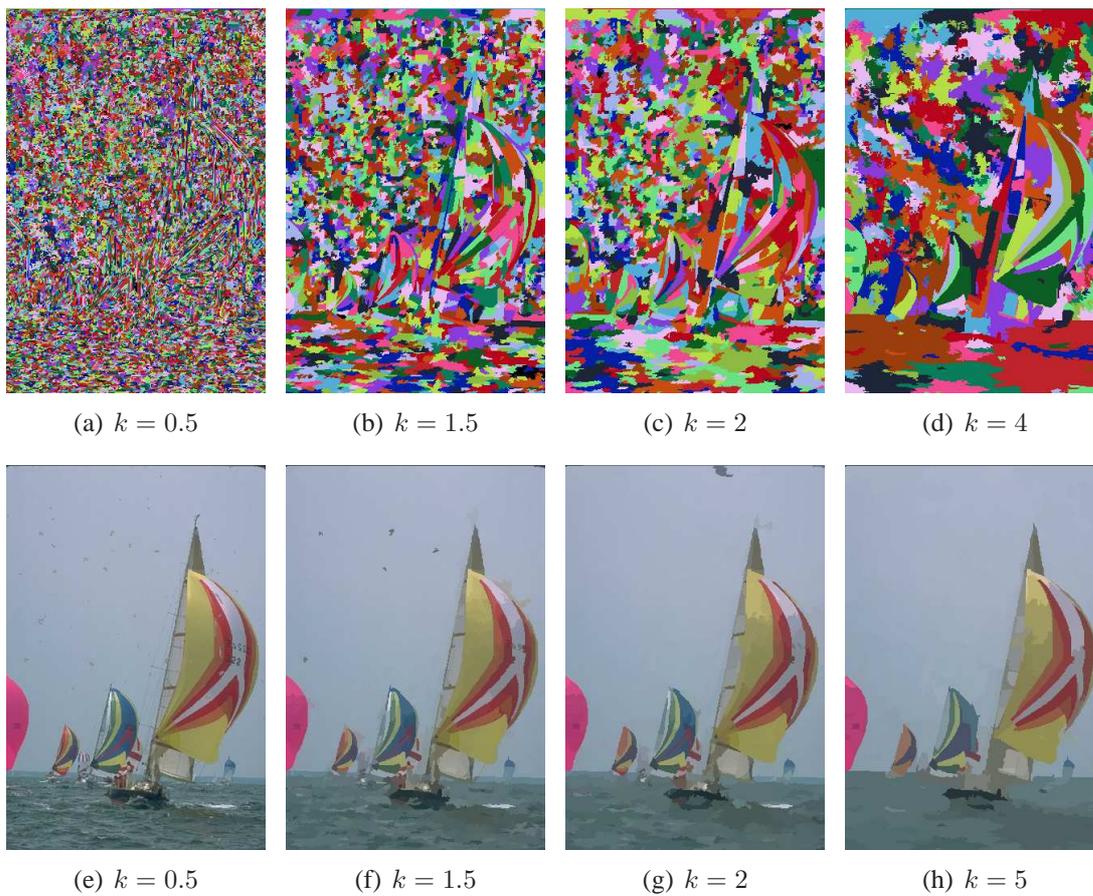


FIG. 7.1 – Partitions par zones homogènes de finesses décroissantes ((a-d) : régions, (e-h) : mosaïques correspondantes).

successifs de la hiérarchie. Tout comme pour l'algorithme du waterfall (« chutes d'eau »), une façon de réaliser ceci est d'appliquer le principe des zones homogènes sur un graphe d'adjacence de régions obtenu par une partition fine par zones homogènes. Chaque région du graphe étant décrite par sa moyenne, on peut appliquer la même règle de croissance, mais sur le graphe cette fois.

Définition (Zones homogènes sur Graphe) Deux noeuds N_p et N_q d'un graphe d'adjacence de régions G appartiennent à une même zone homogène d'une image I ssi $\|\bar{I}(N_p) - \bar{I}(N_q)\| \leq k \times \lambda(\text{Germe}(N_p))$, avec $\text{Germe}(N_p)$ le noeud germe de la région de N_p et $\lambda(N_p) = \frac{1}{n_v} \sum_{N_{p_v} \in V(N_p)} \|\bar{I}(N_p) - \bar{I}(N_{p_v})\|$

avec $\bar{I}(N_p)$ la couleur moyenne des pixels du noeud N_p , $V(N_p)$ désigne l'ensemble des noeud voisins du noeud N_p et n_v le cardinal de cet ensemble. Chaque noeud N_p du graphe est enfilé dans une file hiérarchique avec pour priorité la valeur de $\lambda(N_p)$. L'algorithme de construction d'une hiérarchie de partitions de zones homogènes est alors donné par l'algorithme 1.

λ : entier ; k : réel ; k' : réel ;
 $\lambda \leftarrow 1$; Définir λ_{end}
 $P_\lambda \leftarrow$ Zones homogènes de finesse k de l'image initiale.
 $G_\lambda = (N_\lambda, A_\lambda)$ pour une partition initiale P_λ .
Tant que ($\lambda \leq \lambda_{end}$) **faire**
 $G_{\lambda+1} \leftarrow$ zones homogènes de finesse k' de G_λ
 $\lambda \leftarrow \lambda + 1$
Fait

Algorithme 1: Hiérarchie de partitions par zones homogènes.

L'algorithme prend deux paramètres k et k' . k définit la finesse de la partition initiale et k' définit la finesse des partitions successives de la hiérarchie. Le réglage de k et k' est primordial pour la performance de l'algorithme. Pour nos expérimentations, nous avons arbitrairement fixé ici $k = 1$ et $k' = 1, 5$. Une amélioration de l'algorithme consisterait à déterminer k' automatiquement suivant le niveau de la hiérarchie.

La figure 7.2 présente trois niveaux de hiérarchies de partitions produites par : une LPE hiérarchique non paramétrique (niveaux 0, 5 et 15), une hiérarchie par zones quasi-plates ($\lambda = 0, 5$ et 15), une hiérarchie par connexions par sauts ($k = 5, 10$ et 20) et une hiérarchie par zones homogènes stratifiées ($\lambda = 1, 2$ et 3).

Les segmentations obtenues à partir de critères connectifs tels que les zones quasi-plates, les connexions par sauts ou les zones homogènes stratifiées sont très sur-segmentées dans les niveaux les plus bas. Elles constituent ce que l'on appelle des partitions fines. Utilisées telles quelles ces partitions fines ont un intérêt pour la simplification d'image car elles peuvent constituer des marqueurs très efficaces pour les filtres connexes que sont les nivellements [ANGULO03B, GOMILA01]. Cependant elles présentent également un autre intérêt. Les hiérarchies de partitions telles que les pyramides irrégulières [MEER89] uti-



(a) Image initiale

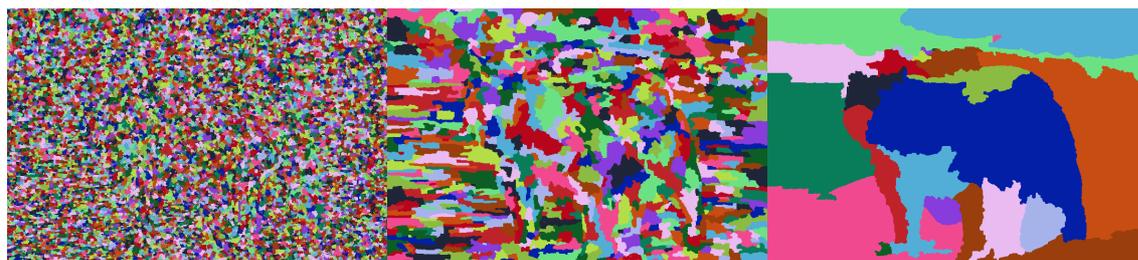
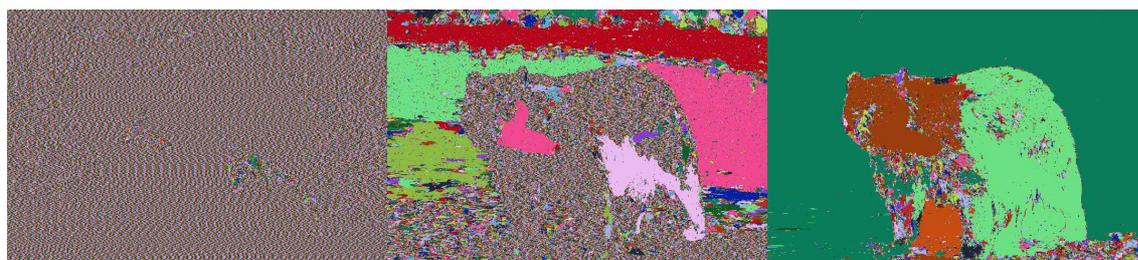
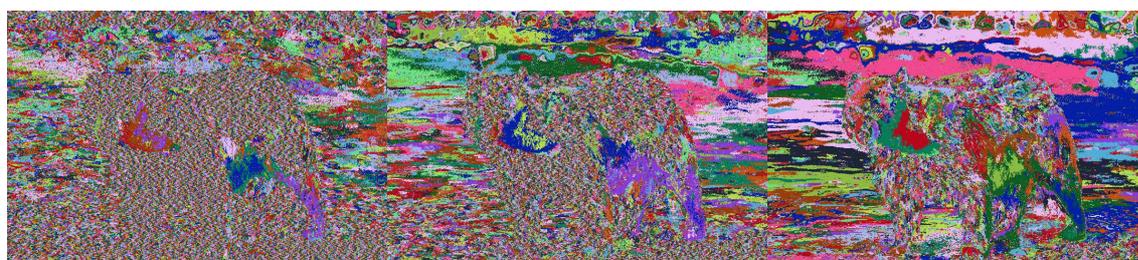
(b) LPE_0 (c) LPE_5 (d) LPE_{15} (e) $\lambda = 0$ (f) $\lambda = 5$ (g) $\lambda = 15$ (h) $k = 5$ (i) $k = 10$ (j) $k = 20$ (k) $\lambda = 1$ (l) $\lambda = 2$ (m) $\lambda = 3$

FIG. 7.2 – Hiérarchies de partitions par (1^{ère} ligne) LPE, (2^{ème} ligne) zones quasi-plates, (3^{ème} ligne) connexions par sauts et (4^{ème} ligne) par zones homogènes stratifiées.

lisent une partition fine comme partition initiale et celle-ci est généralement très simple, à savoir que chaque pixel est considéré comme étant une région. Il semble totalement inutile de définir le niveau le plus bas d'une pyramide irrégulière de cette façon car cela alourdit inutilement la structure hiérarchique en définissant des niveaux de fusion évidents à la base de la pyramide. On préférera donc utiliser une partition fine obtenue par une segmentation utilisant par exemple un critère connectif tel que les zones strictement plates ou les zones homogènes que nous venons de définir. La production de hiérarchies de partitions en utilisant un critère connectif strict comme base de la pyramide irrégulière (la partition la plus fine) nous amène à un double but de simplification et de segmentation d'images.

7.2 Morphologie mathématique couleur

Dans cette section, nous redéfinissons une opération de la morphologie mathématique qui est la Ligne de Partage des Eaux (« algorithme du waterfall ») permettant de produire une hiérarchie de partitions. Cette ligne de partage des eaux utilise un gradient morphologique couleur défini par deux autres opérations de morphologie mathématique que sont l'érosion et la dilatation. Ces dernières opérations font référence à la définition d'un infimum et d'un supremum mais posent le problème de l'ordonnement des couleurs dans un treillis. Nous proposons ici une approche par graphe permettant de pallier cet inconvénient et in fine de redéfinir l'algorithme du « waterfall ».

Depuis de nombreuses années maintenant, le traitement d'images couleur est un domaine de recherche important. En effet, l'information couleur apporte dans de nombreuses applications des résultats supérieurs à ceux obtenus avec des images en niveaux de gris. Mais tout ceci n'est pas sans mal puisque certains problèmes subsistent encore comme c'est le cas en morphologie mathématique. En effet, l'extension des algorithmes d'images en niveaux de gris aux images couleur ou multivaluées n'est pas simple en soi puisqu'il n'existe pas réellement d'ordre naturel sur un ensemble de vecteurs couleur ou plus généralement sur des données multi-variables.

Selon BARNET [BARNET76], plusieurs types d'ordre de vecteurs multidimensionnels existent à savoir : l'ordre marginal, l'ordre réduit, l'ordre partiel et l'ordre conditionnel appelé aussi ordre lexicographique. Posons x_1, x_2, \dots, x_n un ensemble de n vecteurs à p dimensions : $x_i = \{x_{1(i)}, x_{2(i)}, \dots, x_{p(i)}\}$, $x_i \in R^p$, les différents types peuvent donc se formuler de la manière suivante :

1. L'ordre marginal : les vecteurs sont ordonnés selon un ordre scalaire indépendant effectué respectivement sur chaque composante de l'espace couleur étudié. Pour deux vecteurs x_i et x_j , nous avons : $x_i \leq x_j \Leftrightarrow x_{k(i)} \leq x_{k(j)}, \forall k \in \{1, 2, \dots, p\}$;
2. L'ordre réduit : une fonction scalaire $d : R^p \rightarrow R$ est utilisée pour ordonner les vecteurs. Pour deux vecteurs x_i et x_j , nous avons : $x_i \leq x_j \Leftrightarrow d(x_i) \leq d(x_j)$;
3. L'ordre partiel : les données sont regroupées en sous-ensembles pour former des enveloppes convexes minimales ;
4. L'ordre conditionnel : les vecteurs sont ordonnés suivant un ordre hiérarchique des composantes couleurs de l'espace couleur utilisé. Pour deux vecteurs x_i et x_j , nous

avons :

$$x_i \leq x_j \begin{cases} x_{1(i)} < x_{1(j)} \text{ ou} \\ x_{1(i)} = x_{1(j)} \text{ et } x_{2(i)} < x_{2(j)} \text{ ou } \dots \\ x_{1(i)} = x_{1(j)} \text{ et } x_{2(i)} = x_{2(j)} \dots x_{p(i)} < x_{p(j)} \end{cases}$$

L'application directe de la morphologie mathématique aux images couleurs est délicate du fait de la nature vectorielle de la couleur et donc de la nécessité de définir un ordre total des couleurs. Par conséquent, pour utiliser les opérations de morphologie mathématique dans le cadre d'images couleurs, il est nécessaire d'ordonner les couleurs de sorte à vérifier l'existence d'un suprémum et d'un infimum et éviter ainsi les fausses couleurs en imposant que ces derniers appartiennent au même treillis complet L . L'approche généralement employée consiste à utiliser l'ordre lexicographique [HANBUR01]. L'inconvénient majeur est que la plupart des décisions sont prises au niveau de la première composante, c'est pourquoi il est conseillé de définir une priorité sur les composantes de l'espace de représentation couleur étudié et ainsi privilégier celle qui semble la plus intéressante. Il est évident que le choix de l'espace de représentation couleur a également toute son importance dans la qualité des résultats obtenus. Plusieurs auteurs ont étudié les différents types d'ordre exposés précédemment. Nous pouvons citer par exemple ASTOLA ET AL. [ASTOLA90] ou PITAS ET TSALIDES [PITAS91] qui se sont intéressés à l'ordre réduit pour la définition des filtres médians ou encore COMER ET DELP [COMER99] ou ORTIZ ET AL. [ORTIZ01] pour la définition d'opérateurs morphologiques. L'ordre conditionnel a été étudié par plusieurs auteurs dans le cadre de l'utilisation de filtres morphologiques [PETERS97, TALBOT98, IWANOW99, LOUVER02, VARDAV01, ORTIZ00]. KOPPEN ET AL. [KOPPEN99] ont également proposé un ordre partiel pour la morphologie mathématique couleur floue. CHANUSSOT ET LAMBERT [CHANUS98] ont proposé quant à eux un autre ordre par entrelacement de bits basé sur les courbes de remplissage d'espace.

Nous comprenons maintenant que l'extension de la morphologie mathématique aux images couleur est fortement liée à la définition d'un ordre approprié sur les couleurs qui possède des propriétés équivalentes à celles des algorithmes morphologiques en niveaux de gris. Quel que soit l'ordre des couleurs considéré, on doit pouvoir définir les deux opérations de base de la morphologie mathématique à savoir l'érosion et la dilatation qui sont utilisées pour définir des opérations plus complexes. C'est pourquoi, nous reprenons donc la définition de l'érosion couleur ϵ et de la dilatation couleur δ par un élément structurant B d'une image f :

$$\begin{aligned} \epsilon_B f(x) &= \{f(y) : f(y) = \wedge(f(z)), z \in B_z\} \\ \delta_B f(x) &= \{f(y) : f(y) = \vee(f(z)), z \in B_z\} \end{aligned}$$

où \vee et \wedge représentent respectivement le suprémum et l'infimum. Précisons aussi qu'il n'est pas nécessaire de connaître l'ordre de toutes les couleurs du treillis complet pour définir ces notions d'érosion et de dilatation, mais seulement les deux valeurs extrêmes que sont \vee et \wedge et correspondant respectivement à la couleur la plus haute et à la plus basse du treillis complet.

L'application des opérations de morphologie mathématique aux images couleur est assez délicate. Comme nous venons de le présenter, de nombreux auteurs ont utilisé des procédés divers et variés pour mener à bien cette transformation. Néanmoins, quelques problèmes restent posés notamment celui de l'organisation de l'ordre des couleurs dans un treillis complet. La figure 7.3 illustre bien un de ces problèmes en montrant que certaines régions n'ont pas subi correctement l'opération morphologique demandée. Ici on a effectué une érosion couleur lexicographique en RVB (figure 7.3(b)) appliquée sur une image couleur (7.3(a)) et l'on constate que l'érosion ne se comporte pas de la même manière sur l'image (problèmes pour les frontières rouge et jaune).

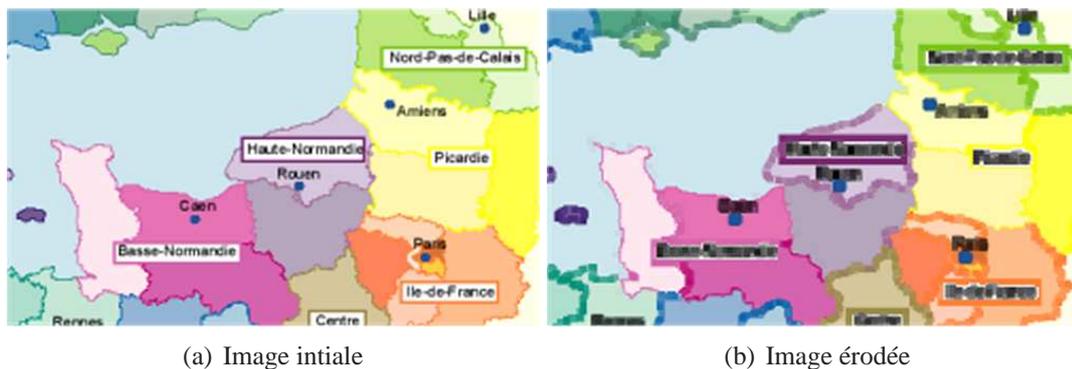


FIG. 7.3 – Exemple d'érosion couleur basée sur un ordre lexicographique.

Après analyse de ces résultats, nous proposons une nouvelle approche basée sur un graphe permettant d'extraire le \vee et l' \wedge d'un treillis et de contrer le problème rencontré dans l'illustration que nous venons de décrire.

7.2.1 Une nouvelle approche basée sur un graphe

Dans cette section, nous proposons donc une alternative à l'approche classique d'ordre total lexicographique de la morphologie mathématique couleur. L'idée principale de cette nouvelle approche est la suivante : l'ordre total produit une projection de tous les pixels de vecteurs couleur 3D sur une ligne qui définit un chemin le long de tous les pixels de l'élément structurant. Considérons un élément structurant B et un Graphe d'Adjacence de Régions G_0 où chaque pixel de B est un noeud du graphe et où les noeuds sont liés en 8 connexité. Pour obtenir un ordre total de tous les vecteurs couleur, nous avons besoin de simplifier le graphe G_0 afin d'obtenir un chemin partant de la borne inférieure \wedge et arrivant à la borne supérieure \vee de l'ensemble couleur. Ce chemin doit posséder deux propriétés. Il doit passer par tous les noeuds mais en ne les traversant qu'une seule et unique fois. Il doit aussi définir un ordre des vecteurs couleurs comme étant un treillis complet : un ordre total et la définition du \vee et de l' \wedge . Il est difficile de trouver aisément un tel chemin parmi toutes les possibilités présentes dans le graphe G_0 . C'est pourquoi, nous proposons de faire une approximation de ce chemin en calculant l'arbre de recouvrement minimal (« Minimum Spanning Tree : MST ») du Graphe d'Adjacence de Régions G_0 et où tous les liens reliant deux noeuds sont valués par une norme L_2 . L'arbre de recouvrement minimal n'est pas très loin de la solution que nous attendons [THEOHA05].

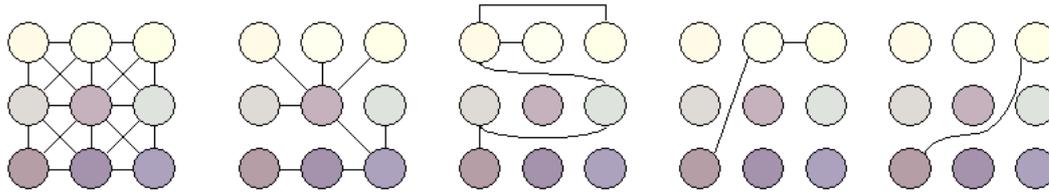


FIG. 7.4 – Processus de décimation du MST du graphe de voisinage (de gauche à droite, le RAG G_0 et les MST successifs G_i avec $i \in [1, 4]$).

La figure 7.4 illustre ce point, le MST du RAG est calculé et les nœuds peuvent être classés comme nœuds internes et externes (feuilles). Si le MST est un ordre des vecteurs couleurs, il définit un chemin parmi les nœuds : ce chemin possède seulement deux nœuds externes et chaque nœud interne est connecté à exactement deux nœuds (ceci définit une projection de l'ensemble des vecteurs couleur sur une ligne). C'est rarement le cas, pourtant nous pouvons faire une supposition sur les propriétés des nœuds du MST puisque c'est une généralisation à des dimensions plus élevées d'une liste à une dimension triée [THEOHA05]. Si un nœud du MST est un nœud interne, il ne peut pas être le \vee ou l' \wedge de l'ensemble des couleurs, car il aurait été considéré dans ce cas comme un nœud externe du chemin d'ordre des vecteurs couleurs. Pour trouver le \vee et l' \wedge de l'ensemble des vecteurs couleur, nous pouvons utiliser cette dernière propriété en construisant un nouveau RAG G_1 constitué uniquement des couleurs possibles : les nœuds externes du MST de G_0 . Chaque nœud de G_1 est lié à tous ses autres nœuds (les externes de $\text{MST}(G_0)$) et le MST de G_1 est calculé. Ce procédé peut être réitéré jusqu'à ce que le MST obtenu à l'itération i soit réduit à deux nœuds externes définissant respectivement le \vee et l' \wedge . Cependant une dernière étape est à effectuer à savoir, définir quel nœud externe est le \vee et par élimination l' \wedge . L' \wedge est identifié comme étant le nœud externe se rapprochant le plus d'une couleur de référence (généralement le noir). A ce titre, l'utilisation d'une couleur de référence a été également employée dans plusieurs travaux en morphologie mathématique et notamment dans [HANBUR01, SORIA-02]. L'algorithme complet se résume dans l'algorithme 2 présenté ci-après. Il nous permet de définir le \vee et l' \wedge d'un ensemble de vecteurs couleurs utilisant une décimation itérative du MST construit sur les vecteurs couleurs candidats du RAG.

```

λ : entier ;
n : entier ;
end : booléen ;
Cref : la couleur de référence ;
end ← faux
λ ← 0
Construire Gλ sur l'élément structurant B
Répéter
    Calculer MST(Gλ)
    n = NombreNoeudsExternes(MST(Gλ))
    Si (n=2) Alors
        | end ← vrai ;
    Sinon
        | λ ← λ + 1
        | Gλ = NoeudsExternes(MST(Gλ-1))
        | Lier de tous les noeuds Gλ
    Fin Si
jusqu'à ce que (end= vrai)
Gλ = ({V1, V2}, {E1})
∨ = argmax d(Vi, Cref) et ∧ = argmin d(Vi, Cref)

```

Algorithme 2: Détermination du \vee et du \wedge d'un ensemble de vecteurs couleurs.

La figure 7.4 illustre la détermination du \vee et de l' \wedge : La première étape est la construction du graphe G_0 , les autres étapes quant à elles présentent le $MST(G_{i-1})$ pour $i \in [1, 4]$ jusqu'à ce que le critère d'arrêt soit atteint. Dans cet exemple, la couleur de référence est le noir, le \vee est donc représenté par le pixel supérieur droit et l' \wedge par le pixel inférieur gauche. Une fois ces deux limites déterminées, nous pouvons effectuer deux opérations de morphologie mathématique : l'érosion et la dilatation sur un voisinage de pixels considéré.

La figure 7.5 illustre pour deux images, des opérations de morphologie mathématique exécutées dans l'espace de représentation couleur RVB avec un élément structurant carré de taille 3×3 par une approche classique d'ordre lexicographique et par une approche basée sur un graphe. La figure 7.5(a) présente l'image (initiale) d'une peinture « Le Chanteur » de JOAN MIRO utilisée dans [HANBUR01]. Les figures 7.5(b) et 7.5(d) présentent respectivement le résultat d'une érosion et d'une dilatation obtenue par une approche classique d'ordre lexicographique. Les figures 7.5(c) et 7.5(e) quant à elles présentent les résultats de ces mêmes opérations mais avec notre approche par graphe. L'avantage principal de notre approche est que nous nous affranchissons de l'ordre lexicographique présentant un inconvénient majeur du fait qu'il donne un rôle dominant à la première composante couleur (le rouge dans notre exemple). Nous pouvons constater l'exactitude de cette remarque par les résultats médiocres obtenus avec l'utilisation de l'ordre lexicographique sur certaines zones rouge et jaune de l'image tandis que notre approche fournit de bons résultats sur ces mêmes zones colorées. Ceci est encore plus évident lorsque nous effectuons ces opérations sur l'image 7.5(f). Sur cette image, une érosion devrait accentuer les

contours des objets mais l'utilisation de l'ordre lexicographique ne donne pas de résultats homogènes et plusieurs couleurs jouent un rôle dominant. En effet, nous nous attendions à ce qu'une opération d'érosion s'exécute de la même manière indépendamment des zones de l'image, or il s'avère que les frontières rouges et jaunes de la figure 7.5(g) ne respectent pas cette hypothèse et sont donc jugées non satisfaisantes. Par contre, ces mêmes frontières illustrées sur la Figure 7.5(h) se trouvent être correctement traitées avec l'approche par graphe que nous proposons et de ce fait les défauts de l'ordre lexicographique sont évités. L'approche par graphe préserve en outre beaucoup mieux les contours.

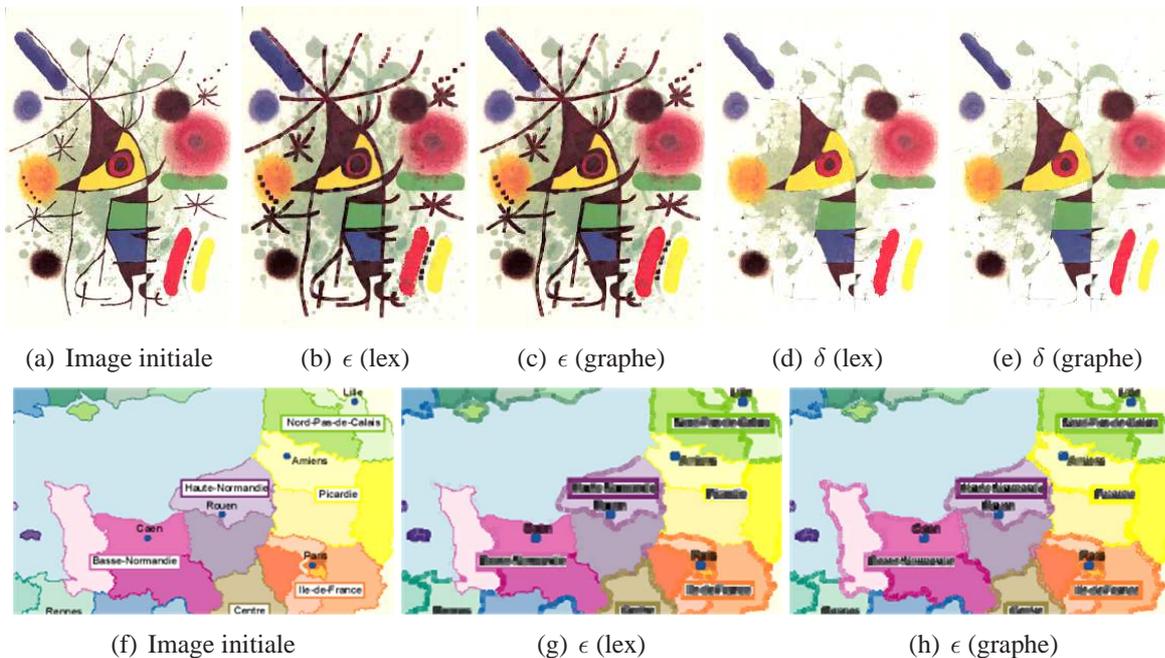


FIG. 7.5 – Comparaison entre une approche lexicographique et une approche par graphe sur une érosion et une dilatation.

La couleur de référence utilisée au dernier niveau du processus de décimation du graphe (dernier cas de la figure 7.4) a une influence sur la détermination du \vee et de l' \wedge . La couleur noire est généralement utilisée comme couleur de référence, néanmoins il pourrait être intéressant d'employer une autre couleur pour des cas spécifiques. Les figures 7.6(a) à 7.6(e) illustrent respectivement le résultat d'une érosion effectuée sur l'image 7.5(a) avec cinq couleurs de référence à savoir : la noire, la rouge, la verte, la bleue et la jaune. Mais afin de mieux visualiser l'impact de la couleur de référence et donc des différences entre les résultats obtenus, nous avons soustrait l'image après érosion à l'image originale pour la couleur noire de référence. La figure 7.6(f) donne cette différence. Nous avons également calculé la différence entre le résultat d'une érosion pour la couleur noire de référence et le résultat d'une érosion pour chacune des autres couleurs de référence citées précédemment. Ces différences entre les érosions obtenues sont illustrées sur les figures 7.6(f) à 7.6(j) et donnent les différences entre une érosion de couleur noire de référence et des érosions de couleurs rouge, verte, bleue et jaune de référence. Nous pouvons alors constater qu'un changement de couleur de référence modifie la façon dont l'érosion agit sur certaines couleurs puisqu'elle favorise les couleurs proches de la référence. Nous n'avons qu'à regarder l'oeil du chanteur (au centre de l'image 7.6(g) pour l'érosion avec la couleur rouge ou

bien encore l'objet allongé jaune (en bas à droite de l'image 7.6(i)) pour l'érosion avec la couleur bleue. Ceci est encore plus flagrant sur l'image érodée avec la couleur jaune comme couleur de référence (figure 7.6(j)) : la majorité des couleurs sont plus proches du jaune que du noir ce qui a pour conséquence de favoriser la disparition de cette dernière.

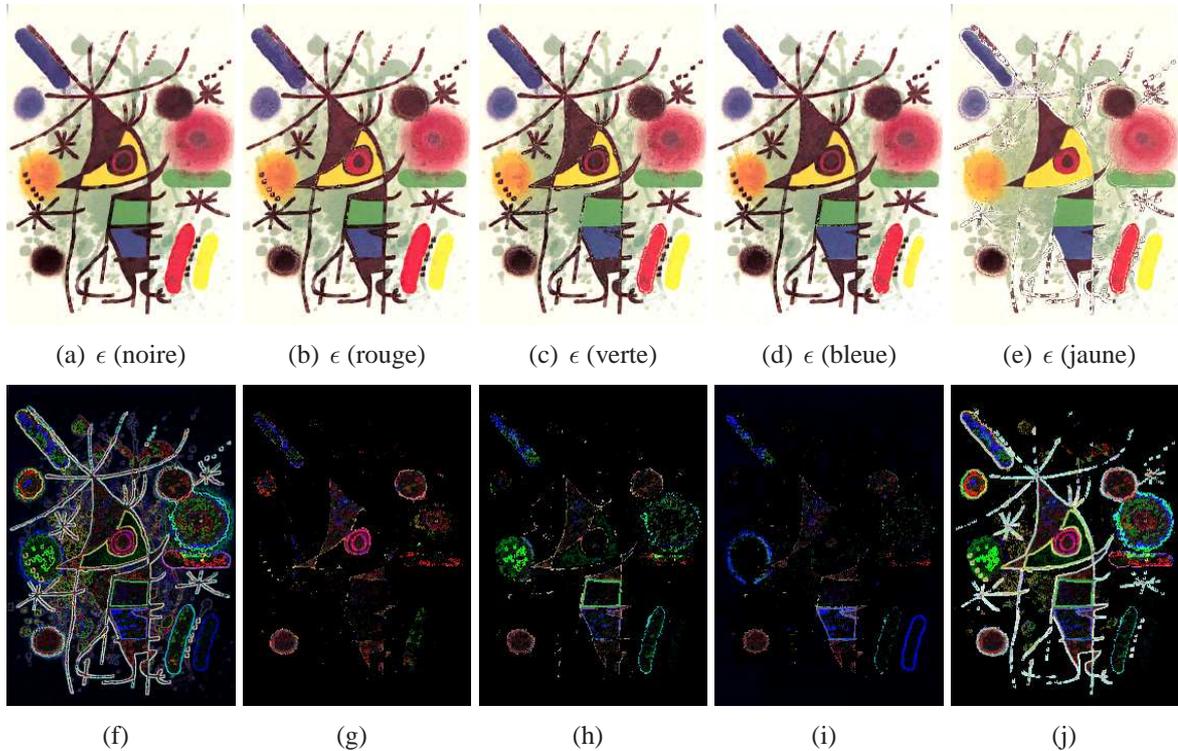


FIG. 7.6 – Exemple de l'influence de la couleur de référence (noire, rouge, verte, bleue, jaune) sur une érosion.

7.2.2 Gradient morphologique couleur

Plusieurs définitions de gradient morphologique existent dans la littérature. Nous pouvons d'ores et déjà citer trois de ces définitions en niveaux de gris : le gradient morphologique se trouvant être le gradient standard, le gradient circulaire centré traitant des valeurs angulaires et le gradient euclidien utilisé pour des fonctions vectorielles et basé sur le calcul d'une distance euclidienne. Le gradient couleur peut lui aussi avoir différentes formulations lorsque la couleur est vraiment considérée. ANGULO ET SERRA [ANGULO03B] définissent une série de gradients couleur basés sur les gradients monochromes que nous venons de rappeler mais en y ajoutant deux changements d'espace de représentation couleur que sont : l'espace IHS et l'espace $L^*a^*b^*$. En ce qui nous concerne, nous proposons différents gradients couleur en rapport avec notre approche par graphe. La définition classique du gradient morphologique pour une image f est donnée par : $\nabla f = \delta(f) - \epsilon(f)$, où f est une image couleur, $\delta(f)$ et $\epsilon(f)$ représentent des vecteurs couleurs mais aussi respectivement l'image dilatée et l'image érodée. Nous pouvons alors proposer plusieurs définitions de gradients morphologiques couleur basés sur une approche par graphe :

1. Gradient supremum : il prend le supremum des gradients marginaux : $\nabla_{\vee} f(x) = \vee[\nabla f_1(x), \nabla f_2(x), \nabla f_3(x)]$, les gradients marginaux étant calculés uniquement sur le \vee et l' \wedge .
2. Gradient de norme L_p : il évalue une distance entre les limites des couleurs : $\nabla_{L_p} f(x) = \|\delta f(x) - \epsilon f(x)\|_p$
3. Gradient perceptuel : il est utilisé dans les espaces de représentation couleur perceptuels tels que $L^*a^*b^*$: $\nabla_P f(x) = \nabla_{L_2} f(x)$, ce gradient est perceptuel chromatique ($\nabla_{PC} f(x)$) quand x est seulement décrit par des composantes chromatiques couleur

La figure 7.7 présente différents types de gradients basés sur une approche classique ou par graphe et calculés dans l'espace de représentation couleur RVB et $L^*a^*b^*$ pour le dernier type de gradient (le gradient chromatique perceptuel). Le gradient $\nabla_{\vee} f$ lex de la figure 7.7(b) est un gradient marginal utilisant une approche morphologique classique tandis que les autres gradients de la figure 7.7 sont des gradients vectoriels utilisant une approche par graphe.

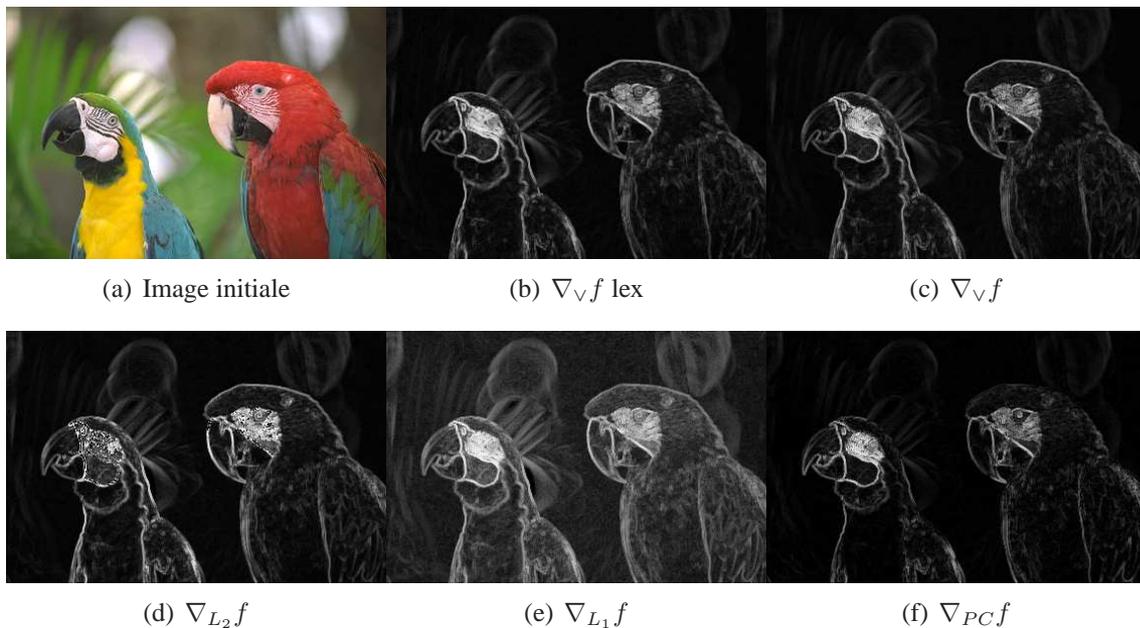


FIG. 7.7 – Exemples de gradients couleur.

7.2.3 Hiérarchie de segmentations par waterfall

La Ligne de Partage des Eaux est l'une des principales opérations de traitement d'images en morphologie mathématique. Cette technique de segmentation s'est avérée être un outil puissant cependant elle présente un inconvénient majeur à savoir l'obtention d'une image fortement sur-segmentée lorsqu'elle est directement appliquée sur l'image initiale. Une approche pour contrer cette sur-segmentation est de produire une hiérarchie de Ligne de Partage des Eaux non paramétrique également connue sous le nom de l'algorithme du waterfall (« chutes d'eau ») instauré par BEUCHER [BEUCHE94]. La ligne de Partage des Eaux est utilisée dans le but de produire une partition de l'image et l'algorithme du waterfall permet de produire une hiérarchie de partitions formant un treillis complet

[SERRA00, SERRA03]. Nous reprenons cet algorithme dans l'algorithme 3 où g représente le gradient, f l'image couleur originale, m l'image mosaïque, ϵ^{rec} une érosion par reconstruction et w la Ligne de Partage des Eaux, plus de détails à ce sujet sont disponibles dans [ANGULO03B].

```

λ : entier ; λend : entier ;
λ ← 1 ; Définir λend
Tant que (λ ≤ λend) faire
  Si (λ=0) Alors
    |  $g_0 = \nabla f$  ;
    |  $w_0 = LPE(g_0) ; m_0(f, w_0)$  ;
  Fin Si
  Si (λ=1) Alors
    |  $g_1 = \nabla m_0 ; w_{1*} = LPE(g_1)$  ;
    | Si ( $x \in w_{1*}$ ) Alors
      | |  $h_1(x) = g_1(x)$ 
    | Fin Si
    | Si ( $x \in w_{1*}^C$ ) Alors
      | |  $h_1(x) = t_{max}$ 
    | Fin Si
    |  $g_1^* = \epsilon_{g_1}^{rec}(h_1) ; w_1 = LPE(g_1^*) ; m_1(f, w_1)$  ;
  Fin Si
  Si (λ > 1) Alors
    |  $g_\lambda = \nabla m_{\lambda-1} ; w_{\lambda*} = LPE(m_{\lambda*})$  ;
    | Si ( $x \in w_{\lambda*}$ ) Alors
      | |  $h_\lambda(x) = g_\lambda(x)$ 
    | Fin Si
    | Si ( $x \in w_{\lambda*}^C$ ) Alors
      | |  $h_\lambda(x) = t_{max}$ 
    | Fin Si
    |  $g_\lambda^* = \epsilon_{g_\lambda}^{rec}(h_\lambda) ; w_\lambda = LPE(g_\lambda^*) ; m_\lambda(f, w_\lambda)$  ;
  Fin Si
  λ ← λ + 1
Fait

```

Algorithme 3: Algorithme du waterfall.

Dans le cadre d'images couleur, l'algorithme du waterfall peut s'avérer très efficace à condition que le gradient couleur calculé sur l'image soit satisfaisant. Nous pouvons illustrer cette remarque en construisant une pyramide de segmentations obtenue à partir de l'algorithme du waterfall avec différents gradients couleur. L'intérêt d'avoir défini dans la section précédente différents gradients couleur basés sur des opérations d'érosions et de dilations utilisant une approche par graphe, nous amène à pouvoir construire plusieurs types de hiérarchies de partitions. Nous présentons sur la figure 7.8 quelques résultats de segmentation (aux niveaux 5 et 6 de la pyramide) suivant le gradient morphologique

couleur utilisé. La figure 7.8(b) utilise un gradient supremum couleur calculé avec un ordre lexicographique. Les autres figures illustrent des segmentations utilisant différents gradients couleur tous calculés avec notre approche par graphe : un gradient supremum (figure 7.8(c)), un gradient L_2 (figure 7.8(d)), un gradient L_1 (figure 7.8(e)), un gradient perceptuel (figure 7.8(f)). Tous ces gradients sont calculés dans l'espace de représentation couleur RVB hormis pour le gradient perceptuel pour lequel le calcul s'effectue dans l'espace de représentation $L^*a^*b^*$. Nous pouvons nous rendre compte de par ces figures que la hiérarchie est plus lisse lorsque notre approche par graphe est utilisée et qu'il est nécessaire d'aller à des niveaux plus élevés de la pyramide. En effet, la segmentation basée sur un gradient supremum calculé avec un ordre lexicographique, obtenue au 5^{ème} niveau de pyramide, présente 235 régions et celle calculée avec notre approche par graphe présente 300 régions au 6^{ème} niveau. Au regard de toutes les segmentations obtenues avec différents gradients couleur calculés avec une approche par graphe, il apparaît que les gradients L_1 (figure 7.8(e)) et perceptuel (figure 7.8(f)) produisent les meilleurs résultats et une meilleure préservation des contours. La norme L_1 se trouve être la plus intéressante car elle produit moins de régions pour un niveau inférieur de la pyramide. La figure 7.9 illustre ces derniers résultats aux différents niveaux d'une hiérarchie de partitions.

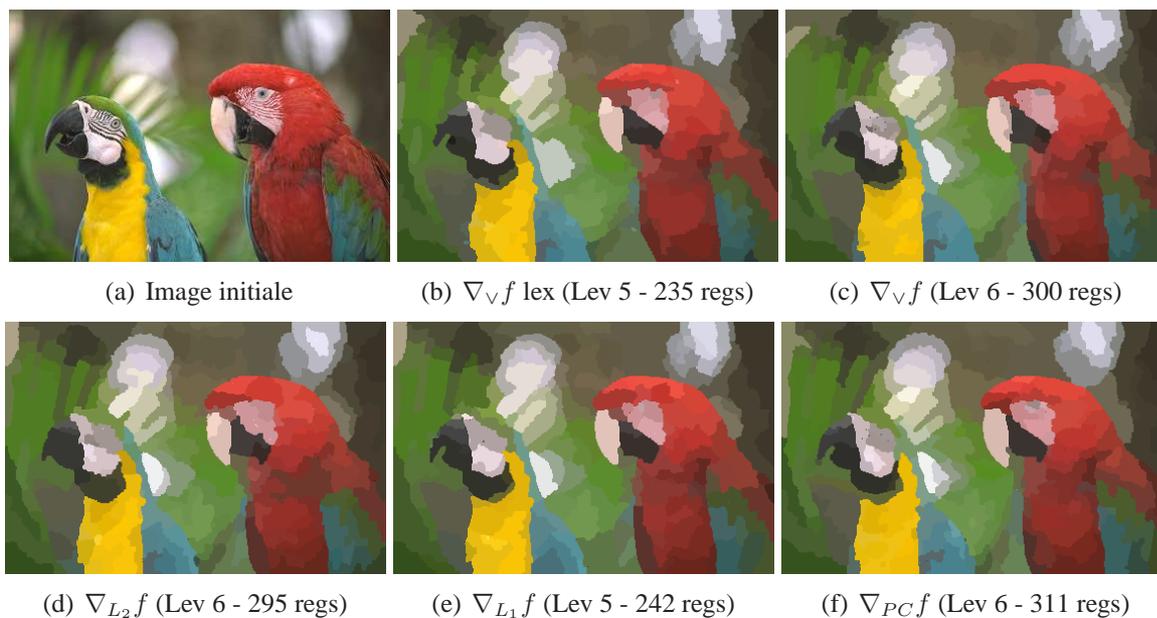


FIG. 7.8 – Résultats de segmentations obtenues avec l'algorithme du waterfall et différents gradients couleur.

7.3 Simplification et segmentation d'image par lissage non linéaire d'un graphe et fusion de régions

Une partition fine obtenue par un critère connectif quelconque est très sur-segmentée, cependant cette partition est fine car elle est très fidèle au contenu de l'image originale. Si l'on construit l'image mosaïque d'une partition fine cela revient donc à effectuer une simplification de l'image car une image mosaïque d'une partition correspond à une image où chaque pixel a comme couleur la couleur moyenne de la région à laquelle il appartient.

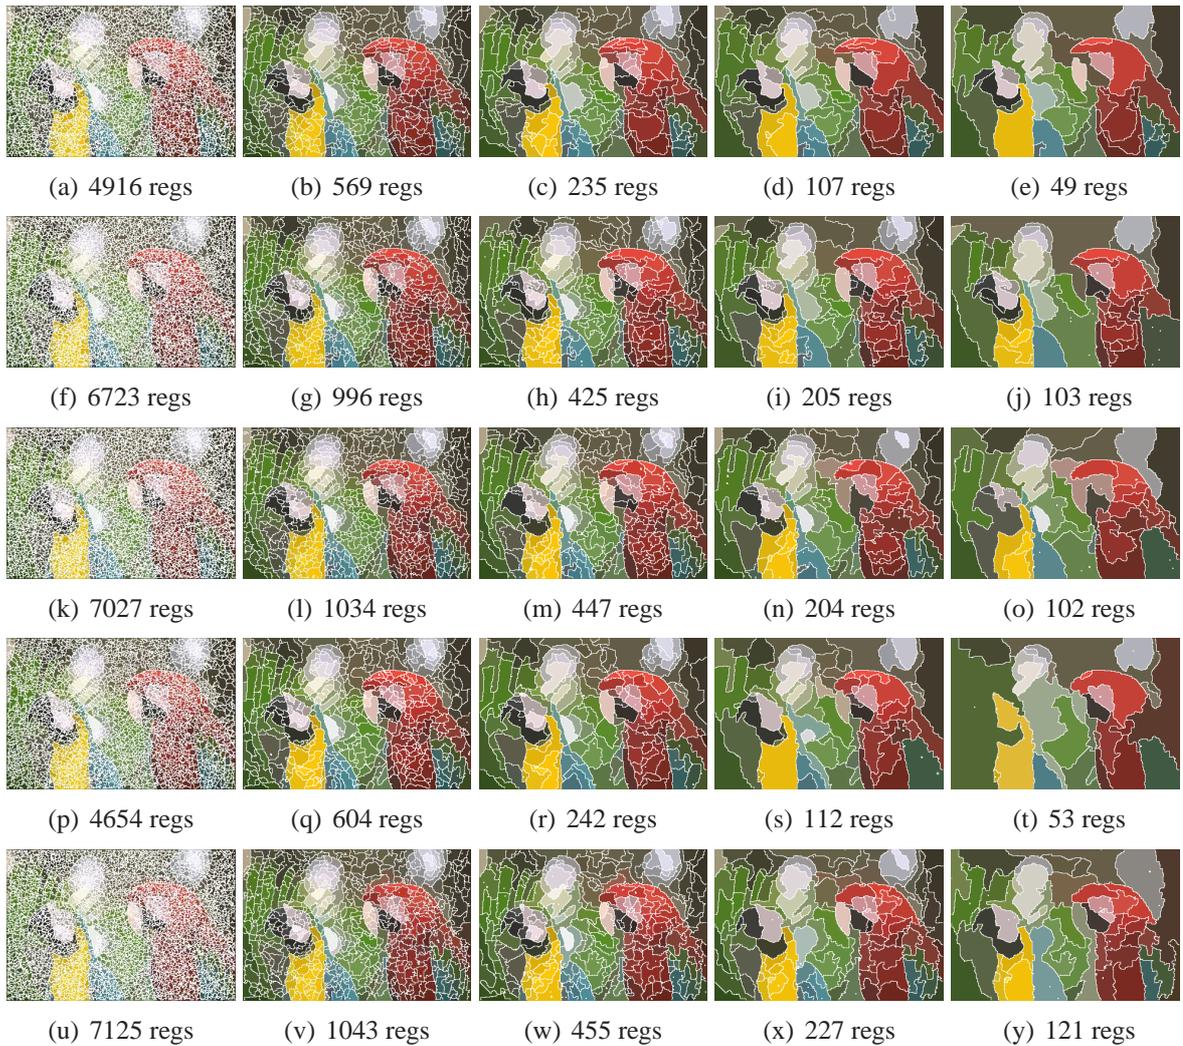


FIG. 7.9 – Hiérarchie de partitions obtenues (niveaux 0, 3, 5, 7, 9) avec l'algorithme de waterfall et différents gradients couleur ($\nabla_{\vee} f$ lex : 1^{ere} ligne, $\nabla_{\vee} f$: 2^{eme} ligne, $\nabla_{L_2} f$: 3^{eme} ligne, $\nabla_{L_1} f$: 4^{eme} ligne, $\nabla_{PC} f$: 5^{eme} ligne).

Cette image mosaïque peut par exemple servir de base à un nivellement comme cela est fait par ANGULO [ANGULO03B].

Nous proposons ici une approche de simplification d'image qui opère directement sur une partition. Cependant, lorsque l'on considère une partition donnée P_k , cela revient à considérer son Graphe d'Adjacence de Régions (RAG) G_k , une hiérarchie de partitions H correspondant alors à une hiérarchie de RAG. Un RAG est composé d'un ensemble de noeuds N représentant des composantes connexes d'une partition et d'un ensemble d'arêtes A connectant deux noeuds voisins. Un RAG est un graphe non orienté et valué noté $G = (N, A)$ où $N = \{1, 2, \dots, K\}$ est l'ensemble de ses noeuds et $A \subset N \times N$ est l'ensemble de ses arêtes (les liens entre les régions adjacentes). $K = |G|$ est le nombre de noeuds du graphe G . On associe à chaque noeud un modèle correspondant à la région que le noeud représente, nous prenons ici un modèle très simple basé sur la couleur moyenne de la région. Les objets composant une image n'étant significatifs qu'à un certain niveau d'échelle, ceci est également valable pour les régions constituant le RAG. Une image étant par nature multi-échelle, nous pouvons représenter cet aspect par des approches de type espace-échelle, c'est à dire considérer une image à différents niveaux de simplification [VANHAM03].

Nous proposons de simplifier une image couleur par un lissage non linéaire opérant directement sur le graphe d'une partition fine [LEZORA05]. Ce lissage a pour but de simplifier les modèles des régions attachés à chaque noeud et donc de produire un ensemble d'images correspondant chacune à un niveau de simplification. Pour lisser un RAG, un processus itératif est utilisé. A partir d'un RAG initial ($t = 0$), un nouveau modèle est calculé pour chaque noeud en fonction de ses voisins et ceci à chaque itération ($t > 0$). Le nouveau modèle est défini par l'expression suivante :

$$N_i^0 = N_i$$

$$N_i^{t+1} = \frac{\sum_j (\alpha_{ij}^t \cdot N_j^t)}{\sum_j \alpha_{ij}^t} \tag{7.1}$$

avec $\alpha_{ij}^t = g(d(N_i^t, N_j^t))$ et N_j^t est un noeud appartenant au voisinage de N_i^t dans le RAG à l'itération t . N_i^t désigne le modèle de la région, dans notre cas c'est la couleur moyenne de la région associée au noeud. d est une norme L_2 et g est une fonction décroissante positive pondérant les influences relatives des voisins du noeud N_i^t . Nous avons choisi $g(s) = e^{-\left(\frac{s}{\sigma}\right)^2}$. Cette approche est similaire à celle de PERONA et MALIK dans le choix de leur fonction pour la diffusion anisotropique [PERONA90]. Le lissage du graphe proposé ici permet de construire un RAG lissé où le modèle associé à chaque noeud (qui correspond à une région de la partition fine initiale) est obtenu en fonction de ses voisins. Ceci permet donc de calculer un RAG simplifié puisque les modèles associés à chaque noeud ont été simplifiés selon leur voisinage. Prise telle quelle cette méthode permet de construire une simplification d'image en associant à chaque pixel le modèle simplifié du noeud correspondant à la région à laquelle il appartient.

La figure 7.10 présente un exemple de lissage par la méthode que nous proposons sur une image couleur en prenant comme partition initiale les zones strictement plates ($\lambda = 0$), c'est à dire dont l'image mosaïque correspond exactement à l'image initiale. Cette simplification aurait très bien pu être obtenue par un lissage similaire opérant directement sur l'image, cependant effectuer le lissage sur le RAG permet d'accélérer considérablement le traitement (environ d'un facteur 5 par rapport à une approche classique). Ceci est intéressant à plusieurs titres. Tout d'abord cela représente une alternative rapide de la simplification classique d'image et cela ne déplace pas les frontières des régions composant l'image. D'autre part le RAG dont les noeuds ont été simplifiés peut être utilisé pour obtenir facilement une partition plus simple que celle de la partition fine initiale. En effet, puisque les modèles des régions attachés à chaque noeud sont simplifiés à chaque itération, des régions similaires vont tendre vers des modèles similaires et l'on peut donc procéder à une fusion des régions dont les modèles sont très proches. Cela va avoir pour conséquence supplémentaire d'accélérer à nouveau le traitement car le lissage opérera sur un graphe décimé. On peut par exemple appliquer la simplification à l'arbre de recouvrement minimum ($MST(G_k)$) du graphe G_k . Le graphe étant alors très réduit le lissage est plus prononcé car chaque région possède moins de régions adjacentes dans le graphe comme l'illustrent les figures 7.10(e) à 7.10(h).

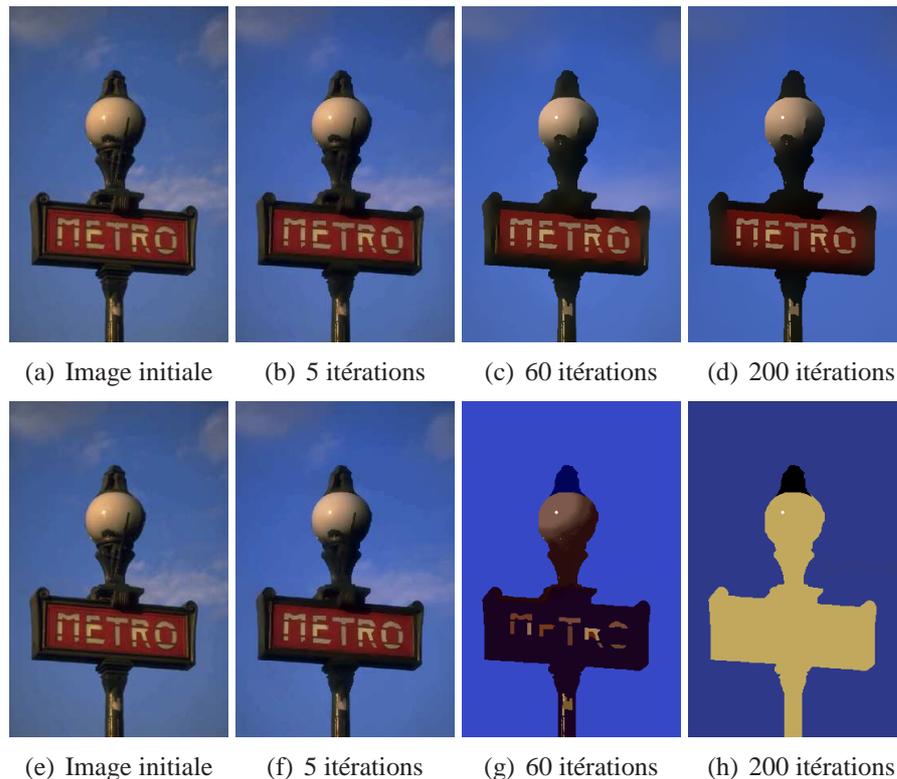


FIG. 7.10 – Ensemble d'images simplifiées dans un schéma espace-échelle sur graphe après 0, 5, 60 et 200 itérations du filtre de lissage ((a-d) : graphe, (e-h) : arbre de recouvrement minimum).

7.3.1 Hiérarchie de partitions par fusion de régions

La méthode de simplification d'images couleur que nous venons de présenter est très intéressante pour obtenir une représentation simplifiée des modèles attachés à chaque région. Cependant la simplification opérant selon un modèle espace-échelle directement sur l'image, cela ne produit pas une hiérarchie de partitions mais une hiérarchie d'images simplifiées à différents niveaux d'échelle. Nous pouvons tirer parti de la simplification des modèles de chaque région du graphe pour simplifier également la partition correspondant au graphe. En effet, la simplification de l'image tend à rapprocher des modèles similaires et les régions devenues similaires peuvent alors fusionner [LEZORA05]. L'idée de fusionner des régions provenant d'une partition initiale est assez ancienne [HOROWI76], elle est à la base de beaucoup de méthodes hiérarchiques dont les pyramides irrégulières [MEER89].

Créer une hiérarchie de partitions à partir d'une fusion de régions consiste simplement à fusionner les régions deux à deux en enlevant les arêtes correspondantes du RAG [MAKROG01]. Pour chaque seuil $\lambda \in \Lambda$, on peut définir un noyau de contraction [KROPAT95] du graphe qui fusionne les régions dont les arêtes les reliant ont une similarité en dessous du seuil λ , cela représente donc une partition P_λ obtenue à l'échelle λ . La construction de P_λ équivaut à trouver les régions connexes maximales du graphe dont la similarité est inférieure au niveau d'échelle λ et $H = \{P_\lambda\}_{\lambda \in \Lambda}$ est bien une hiérarchie de partitions emboîtées car chaque région de $P_{\lambda+1}$ est une union disjointe de régions de P_λ . Nous proposons de combiner ce type de hiérarchie de partitions par fusion de régions avec la méthode de simplification d'image par lissage non linéaire du graphe d'adjacence. Le principe est itératif et consiste à alterner simplification des modèles et fusion des régions. A chaque itération les modèles des régions sont simplifiés par notre méthode de lissage et les régions similaires au sens d'un critère de similarité sont fusionnées. Le lissage des modèles des régions tendant à rapprocher des modèles similaires, les régions correspondantes peuvent être fusionnées.

Pour cette stratégie de fusion de régions définie sur un RAG, nous allons définir les trois notions habituelles que sont le modèle de régions, l'ordre de fusion et le critère de fusion [SALEMB00, GARRID98].

1. Le modèle des régions utilisé est très simple et constitué uniquement de la couleur moyenne de chaque région : $M_{R_i} = N_i^t$. L'union de deux régions devant être calculée rapidement, il est défini directement à partir des modèles des deux régions devant fusionner : $M_{R_i} \cup M_{R_j} = N_i^t \cup N_j^t$. Chaque région est décrite par un vecteur de quatre attributs où $C_X(p)$ étant la composante couleur X du pixel p :

$$M_{R_i} = \left(\sum_{p \in R_i} C_R(p), \sum_{p \in R_i} C_V(p), \sum_{p \in R_i} C_B(p), |R_i| \right);$$

2. L'ordre de fusion utilise directement la similarité entre deux régions telle que nous l'avons définie pour la simplification des modèles de régions : $O(R_i, R_j) = O(N_i^t, N_j^t) = d(N_i^t, N_j^t)$. Pour effectuer la fusion des régions répondant au critère de fusion, les régions sont classées dans une file hiérarchique prioritaire selon leur similarité établie par l'ordre de fusion, et les deux régions dont la similarité est la plus faible sont fusionnées. Effectuer une fusion revient à supprimer l'arête de coût minimum de la

file hiérarchique, à mettre à jour le modèle de région de leur fusion ainsi que les similarités portées par les arêtes de toutes leurs régions adjacentes, certaines arêtes étant également supprimées. Ceci nécessite d'utiliser une file hiérarchique prioritaire qui permet des opérations rapides d'insertion et de suppression à l'aide d'un arbre binaire de recherche ;

3. Le critère de fusion est défini par $C(R_i, R_j) = O(R_i, R_j) < \lambda$ et il permet de définir une hiérarchie de partitions pour des valeurs croissantes de λ . Nous résumons l'approche dans sa globalité par l'algorithme 4.

```

 $\lambda$  : entier ;  $\lambda_{end}$  : entier ;
 $\lambda \leftarrow 1$  ; Définir  $\lambda_{end}$ 
 $G_\lambda = (N_\lambda, A_\lambda)$  pour une partition initiale  $P_\lambda$ .
Tant que ( $\lambda \leq \lambda_{end}$ ) faire
  Pour les noeuds  $N_i \in N_\lambda$  faire
    Simplifier le modèle du noeud  $N_i$  en appliquant une fois le lissage non
    linéaire.
  Fin Pour
  Pour les arêtes  $A_l = (N_i, N_j) \in N_\lambda \times N_\lambda$  faire
    Si ( $O(N_i, N_j) < \lambda$ ) Alors
      Ajouter  $A_l$  au noyau de contraction  $NC_{\lambda, \lambda+1}$ 
    Fin Si
  Fin Pour
  Contracter le graphe  $G_\lambda$  avec le noyau de contraction  $NC_{\lambda, \lambda+1} : G_{\lambda+1} =$ 
   $Contraction[G_\lambda, NC_{\lambda, \lambda+1}]$ 
   $\lambda \leftarrow \lambda + 1$ 
Fait

```

Algorithme 4: Hiérarchie de partitions par simplification et fusion de régions.

La figure 7.11 présente des résultats obtenus par notre approche de création d'une hiérarchie de partitions par simplification et fusion au niveau du graphe d'adjacence pour différentes partitions fines initiales : par zones strictement plates (lignes 1 et 2), par LPE (lignes 3 et 4), par zones homogènes de finesse $k = 1$ (lignes 5 et 6). Pour chaque hiérarchie sont fournies les images mosaïques et les régions correspondantes. On constate que la combinaison de la simplification et de la fusion permet d'obtenir des hiérarchies possédant peu de niveaux. De plus la partition fine initiale a une influence sur les niveaux produits par la hiérarchie. Partant des zones strictement plates (c'est-à-dire exactement l'image originale, mais sans partir au niveau du pixel), les premiers niveaux produisent des simplifications de l'image qui sont très proches de l'image originale alors que pourtant le nombre de régions a très grandement diminué (dans l'ordre croissant des niveaux nous avons un nombre de régions variant comme ceci : 239800, 162402, 89716, 48424, 27381, 15854, 9568) et cependant la dégradation de l'image dans les premiers niveaux est perceptible mais pas gênante. Pour les trois hiérarchies, les niveaux supérieurs permettent d'obtenir des segmentations des principaux objets visuels et ceci dès les niveaux intermédiaires.

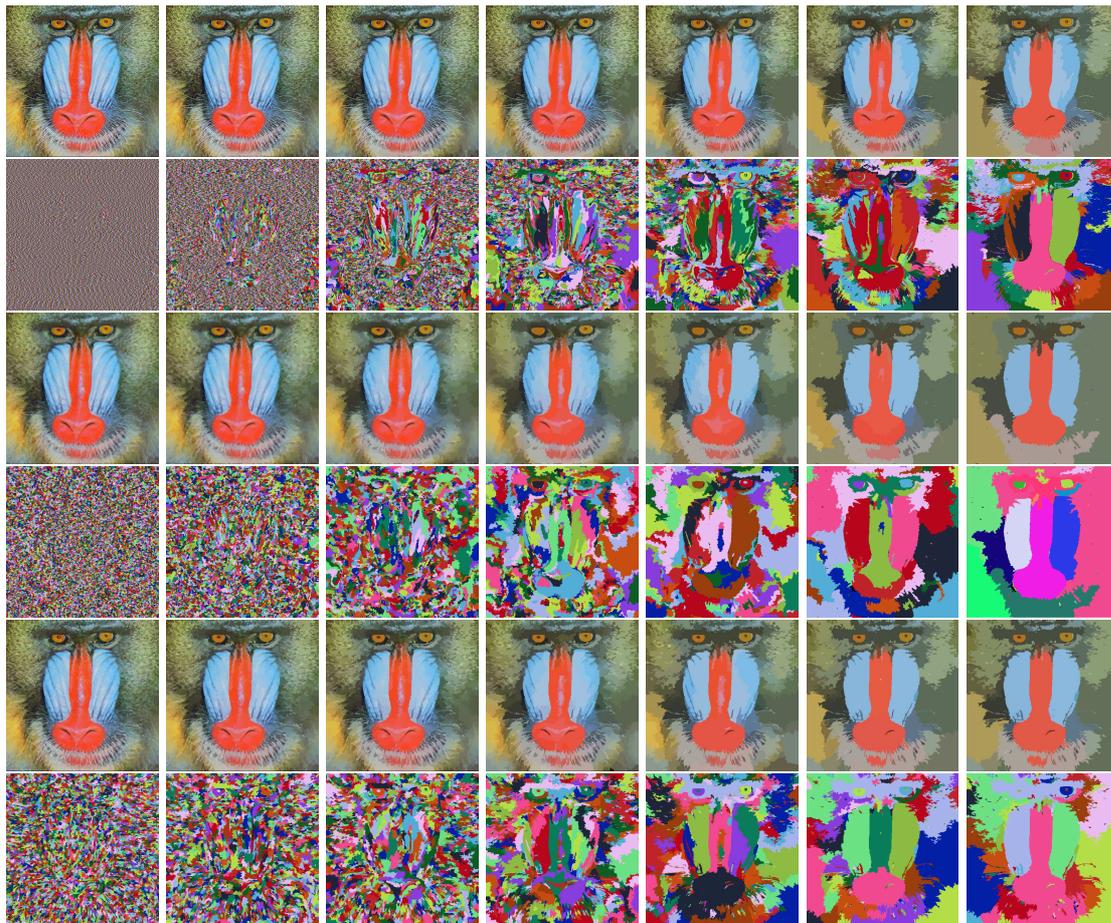


FIG. 7.11 – Hiérarchie de partitions produite par l'approche proposée pour une partition fine par zones plates (niveaux 1, 3, 5, 7, 9, 11, 13), LPE (niveaux 1, 3, 5, 7, 9, 11, 13) et zones homogènes de finesse $k = 1$ (niveaux 1, 3, 4, 6, 8, 10, 11).

La figure 7.12 montre l'évolution de l'erreur quadratique moyenne (MSE : Mean Squared Error) entre l'image mosaïque et l'image originale. On retrouve les premières étapes de simplification où l'image mosaïque est très proche de l'image originale (surtout partant d'une partition à zones plates) puis dans les derniers niveaux la simplification devient grossière et elle correspond à une sur segmentation. Ceci est évidemment le reflet d'un compromis entre qualité visuelle (fidélité aux données) et performance (complexité de la partition engendrée). On peut également proposer une variante de l'algorithme qui consiste à ne pas faire varier le seuil de fusion, c'est à dire avoir toujours $O(N_i, N_j) < 1$ au cours des itérations, le critère de fusion ne permettant alors de fusionner que des régions très similaires comme l'illustre la figure 7.13. Cela produit également de très bonnes hiérarchies mais elles possèdent nettement plus de niveaux. Par rapport au paradigme classique de la segmentation morphologique qui consiste à simplifier l'image et à la segmenter ensuite [SERRA03], notre approche permet de combiner ces deux étapes dans une hiérarchie de partitions.

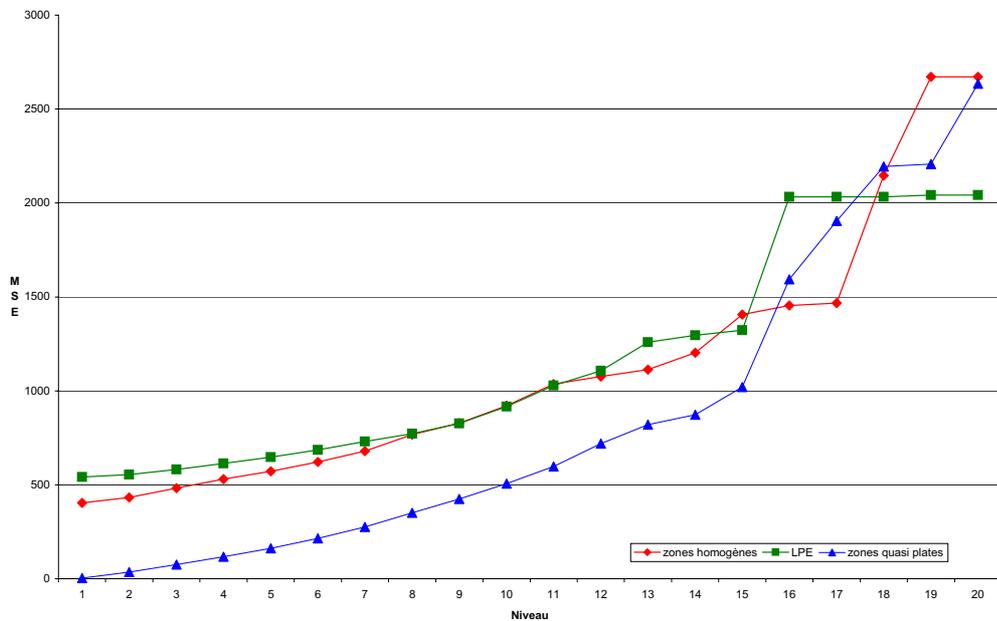


FIG. 7.12 – MSE des hiérarchies de la figure 7.11.

7.4 Evaluation d'une hiérarchie de partitions

Nous venons de présenter, dans ce chapitre, différentes approches permettant de créer une hiérarchie de partitions et représentant donc un empilement de segmentations emboîtées obtenues à différents niveaux. La première partition (partition fine) présente un nombre de régions important pouvant aller jusqu'au nombre total de pixels dans l'image tandis que les partitions suivantes voient leur nombre de régions diminuer au fur et à mesure que l'on se rapproche du sommet de la pyramide et donc d'une partition ne présentant

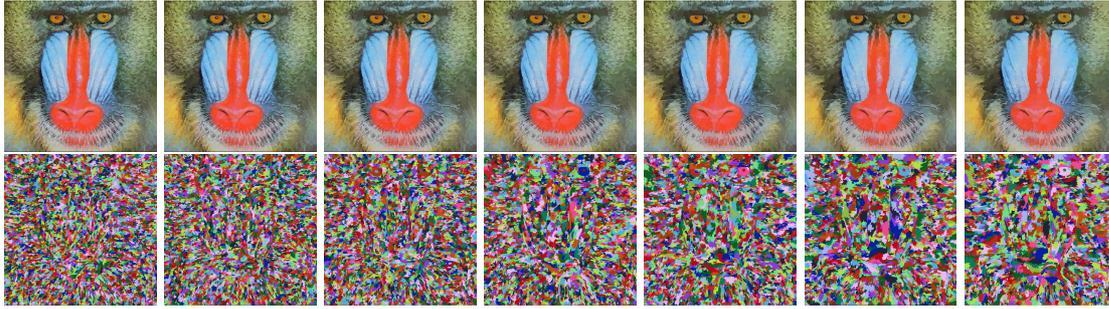


FIG. 7.13 – Hiérarchies de partitions produites par l'approche proposée pour une partition fine par zones homogènes de finesse $k = 1$ (niveaux 1, 3, 4, 6, 8, 10, 11) sans variation du seuil de fusion.

qu'une seule région. Dans la littérature, ces méthodes de production de hiérarchie de partitions sont principalement utilisées pour deux applications que sont la simplification et la segmentation d'images. Dans le cadre de la simplification d'images, ce sont généralement les premiers niveaux de la hiérarchie qui sont employés afin de ne pas détériorer les objets dans l'image et principalement les contours. En ce qui concerne l'application à la segmentation d'images, il est plus courant de recourir à des niveaux de hiérarchie plus élevés. Cependant, si l'on désire choisir de façon automatique le meilleur niveau d'une hiérarchie, nous devons disposer d'une méthode de comparaison de deux partitions d'une hiérarchie.

Ceci rejoint un principe énoncé sous le nom de principe de comparaison par KOEPLER ET AL. [KOEPL94] : « Nous adoptons un principe sans lequel aucune discussion sur la segmentation ne peut avoir lieu, et que nous appellerons principe de comparaison. Selon ce principe, étant donné deux segmentations différentes d'une même donnée, nous pouvons toujours décider laquelle de ces deux doit être considérée comme meilleure que l'autre (ou équivalente). Nous supposons donc l'existence d'un ordre total sur l'ensemble des segmentations possibles, ce qui se traduit par le fait qu'il existe une fonctionnelle réelle E telle que si $E(M_1) < E(M_2)$, alors la segmentation M_1 doit être considérée comme meilleure que la segmentation M_2 ».

Le principe de comparaison s'inscrit dans le cadre des approches variationnelles qui associent à une segmentation une mesure d'énergie. Plus l'énergie est petite plus la segmentation est de qualité. L'énergie proposée par MUMFORD ET SHAH [MUMFOR89] peut être vue comme un modèle général de segmentation par méthodes variationnelles. Selon ce formalisme, la segmentation minimale existe mais n'est pas unique. Pour chaque image un ensemble de segmentations minimales existent.

Selon le principe de comparaison, la formulation d'un problème de segmentation revient à spécifier une fonction d'énergie [GUIGUE01, GUIGUE03A] : $E : M \times I \rightarrow R^+$ sur l'ensemble des segmentations M possibles et sur l'image initiale I et à définir une solution comme la segmentation $M^*(I)$ qui minimise cette énergie et donc pouvant être définie sous la forme suivante :

$$M^*(I) = \underset{M_k \in M}{\operatorname{argmin}} E(M_k, I) \quad (7.2)$$

Cette formulation soulève un problème de compromis car il n'est pas évident qu'il existe une seule et unique meilleure segmentation d'une image. Pour toute énergie censée respecter le principe de comparaison, il va falloir faire un compromis entre la qualité de la segmentation (par rapport à l'image initiale) et sa complexité. La qualité de la segmentation décrit la capacité à décrire fidèlement les données initiales et la complexité de la segmentation décrit la simplicité du modèle [MUMFOR89]. GUIGUES a réalisé une étude sur la modélisation formelle de ce type d'énergie et elle peut, dans un cadre général, s'écrire de la manière suivante [GUIGUE01, GUIGUE03A] :

$$E(M, I) = D(M, I) + C(M) \quad (7.3)$$

Le premier terme D correspond à un terme d'attache aux données (la fidélité aux données initiales) et le second terme correspond à un terme de complexité. Par exemple dans la fonctionnelle constante par morceaux de MUMFORD ET SHAH, la complexité dépend uniquement du modèle M et est décrite par la longueur des frontières des régions. Cela repose sur un *a priori* fort qui sous-entend que les frontières doivent être simples et lisses et de plus la longueur des frontières n'est pas forcément significative de la simplicité des régions. Ce type de formalisme a été repris par GUIGUES dans le cadre d'une minimisation d'énergie dans une hiérarchie de partitions par fusion de régions [GUIGUE01, GUIGUE03A]. Un autre type de fonction d'énergie a été proposé par BOYKOV ET AL. [BOYKOV01] qui propose de prendre en compte la structure topologique du graphe d'adjacence des régions dans le terme de complexité, celui-ci dépend alors du modèle et de l'image initiale, ce qui nous amène à la formulation suivante :

$$E(M, I) = D(M, I) + C(M, I) \quad (7.4)$$

BOYKOV ET AL.[BOYKOV01] ont montré que la minimisation d'une telle fonction d'énergie est un problème NP-complet si l'on cherche la meilleure segmentation directement à partir de l'image où chaque pixel est une région. Ils ont proposé alors des stratégies d'approximation permettant de trouver un minimum local de cette énergie. Dans le cadre des hiérarchies de partitions, le problème est beaucoup plus simple. Les partitions sont connues et l'on cherche juste à en extraire la « meilleure ». Nous proposerons donc une fonction d'énergie adaptée aux hiérarchies de partitions et qui permettra de quantifier la qualité d'une partition. Pour cela nous pouvons faire un parallèle entre la modélisation de l'énergie proposée par BOYKOV ET AL.[BOYKOV01] et deux notions : celle de classification et celle liée aux coupures dans les graphes. Pour la classification, $D(M, I)$ représente l'erreur intra-classe et $C(M, I)$ l'erreur inter-classe. Pour les coupures dans les graphes, $D(M, I)$ représente un terme d'attache aux données et $C(M, I)$ un terme de régularisation. LEZORAY ET CHARRIER dans [LEZORA04] se basent sur ces remarques et sur le formalisme de BOYKOV ET AL. pour modéliser deux quantités permettant de trouver un compromis entre la qualité de la segmentation et la complexité. L'énergie proposée et définie ci-dessous est minimisée pour obtenir le réglage d'un paramètre multi-échelle d'une coalescence morphologique non supervisée d'histogrammes 2D ainsi que dans le cadre de la simplification par fusion de régions adjacentes.

$$E(M, I) = D(M, I) + C(M, I) = \alpha_d \times \left(\sum_{i=1}^{\theta(G)} \frac{e_i^2}{1 + \log(N_i)} \right) + \alpha_c \times \left(\sum_{j=1}^{\theta(G)} \sum_{k>j}^{\theta(G)} L_{j,k} \right) \quad (7.5)$$

où $\alpha_d = \frac{\sqrt{\theta(G)}}{1000 \times h \times w}$ et $\alpha_c = \frac{1}{|L|}$ représentent respectivement les poids de normalisation de la qualité de la segmentation et de la complexité du modèle. G désigne le Graphe d'Adjacence de Régions obtenu à partir du modèle de segmentation M , $\theta(G)$ le nombre de régions du modèle, L l'ensemble des arêtes, $|L|$ le nombre d'arêtes du graphe G , $h \times w$ la taille de l'image I . N_i représente le nombre de pixels de la région R_i , $L_{j,k}$ le poids de l'arête reliant les deux régions R_j et R_k dans le RAG, e_i^2 quantifie l'erreur couleur moyenne de la région R_i (la somme des écarts quadratiques entre les vecteurs couleur de l'image originale et la moyenne couleur de la région R_i).

$D(M, I)$ est une extension de la mesure de BORSOTTI ET AL. et correspond à un terme d'attache aux données. Ce terme prend en compte la distribution des couleurs pour chaque région en fonction de leur aire, cela correspond à une énergie interne aux régions comme cela a été proposé initialement par MUMFORD ET SHAH [MUMFOR89], l'image étant considérée constante par morceaux. $C(M, I)$ décrit la complexité du graphe en tenant compte non seulement de sa structure topologique mais également des valeurs associées aux arêtes. Les arêtes du graphe sont pondérées par une distance entre deux régions, ce qui permet de décrire la similarité entre elles.

7.4.1 Une mesure d'énergie

La fonction d'énergie que nous proposons est basée sur le modèle $E(M, I) = D(M, I) + C(M, I)$ de BOYKOV ET AL. et est utilisée dans un but de segmentation d'images couleur. Cette énergie offrira une évaluation de la qualité d'une segmentation et la minimisation de celle-ci permettra de définir le niveau optimal d'une hiérarchie de partitions présentant un bon compromis entre la qualité de la segmentation obtenue par rapport à l'image initiale et sa complexité comme nous pouvons le retrouver dans les travaux de PETROVIC ET VANDERGHEYNST, MARTINEZ-USO ET AL., CORSO ET AL [PETROV03, MARTÍN04, CORSO04]. Nous considérons que l'énergie est mesurée sur le graphe d'adjacence correspondant d'une partition donnée. L'énergie proposée est très proche de celles de LEZORAY ET CHARRIER [LEZORA04] et BOYKOV ET AL. [BOYKOV01] et s'exprime de la manière suivante :

$$E(M, I) = D(M, I) + C(M, I) = \alpha_d \times \sum_{i=1}^{\theta(G)} \frac{e_i}{N_i} + \alpha_c \times \sum_{i=1}^{\theta(G)} \left[\frac{1}{\varphi(R_j)} \sum_{j=1}^{\varphi(R_j)} d(R_i, R_j) \right] \quad (7.6)$$

avec $\alpha_d = \frac{100 \times \sqrt{\theta(G)}}{h \times w}$ et $\alpha_c = \frac{1}{|L|}$ représentant respectivement les poids de normalisation de la qualité de la segmentation et de la complexité du modèle, $h \times w$ la taille de l'image I , $\varphi(R_j)$ le nombre de régions voisines de la région R_i , $\theta(G)$ le nombre de régions du modèle et $|L|$ le nombre d'arêtes du graphe G . e_i quantifie l'erreur couleur moyenne

de la région R_i (la norme L_2 entre les couleurs des pixels de l'image originale et la couleur moyenne de la région). N_i représente le nombre de pixels de la région R_i . $d(R_i, R_j)$ désigne la distance entre deux régions R_i et R_j . L'erreur e_i peut être établie selon un modèle constant par morceaux ou gaussien. La distance $d(R_i, R_j)$ peut prendre différentes formulations suivant une métrique que nous choisirons parmi les distances Euclidienne, de Student, EMD, de Mahalanobis ou de Hotteling.

L'attache aux données $D(M, I)$ est globalement décroissante dans une hiérarchie de partitions, alors que le terme $C(M, I)$ est globalement croissant. Ces deux termes antagonistes que nous pouvons retrouver sur la figure 7.14 traduisent bien la notion de compromis entre fidélité aux données et simplicité du modèle. L'énergie $E(M, I)$ sera donc globalement décroissante dans une hiérarchie de partitions et nous chercherons à en extraire un minimum local, ce qui permettra de déterminer automatiquement le meilleur niveau d'une hiérarchie. La minimisation d'énergie nous permettra de trouver un compromis entre une sur et une sous segmentation en tenant compte de l'attache aux données et de la complexité de la segmentation obtenue. Le terme d'attache aux données permettra de ne pas trop s'éloigner des données initiales et permettra d'obtenir des segmentations qui seront suffisamment compactes et proches de l'image originale.

La définition de l'énergie que nous venons de présenter faisant intervenir une distance entre régions (dans le calcul du terme de complexité C) et un modèle de région (dans le calcul du terme de la qualité de la segmentation D), nous allons rappeler quelques unes de ces métriques ainsi que les deux principaux modèles de région utilisés et montrer l'importance de leur choix dans la détermination de la meilleure segmentation. Les métriques de mesure de similarité entre deux régions que nous avons retenues sont les suivantes :

- la distance euclidienne entre deux régions R_i et R_j se formule de la manière suivante :

$$d_{Euclidienne}(R_i, R_j) = \left(\sum_{C \in X, Y, Z} \left(\bar{I}_{R_i}^C - \bar{I}_{R_j}^C \right) \right)^{\frac{1}{2}} \quad (7.7)$$

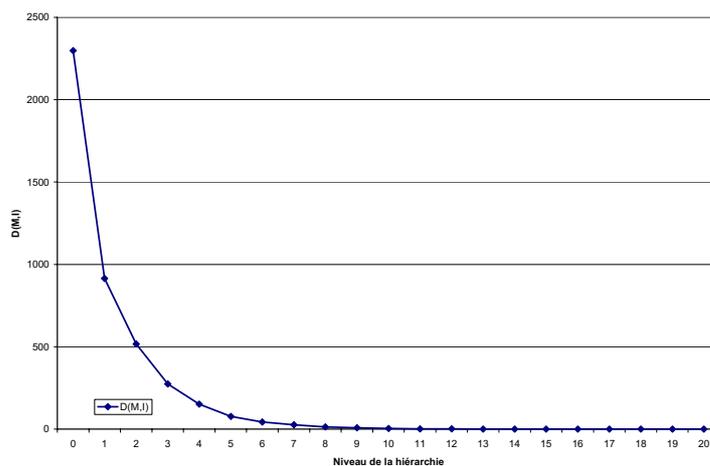
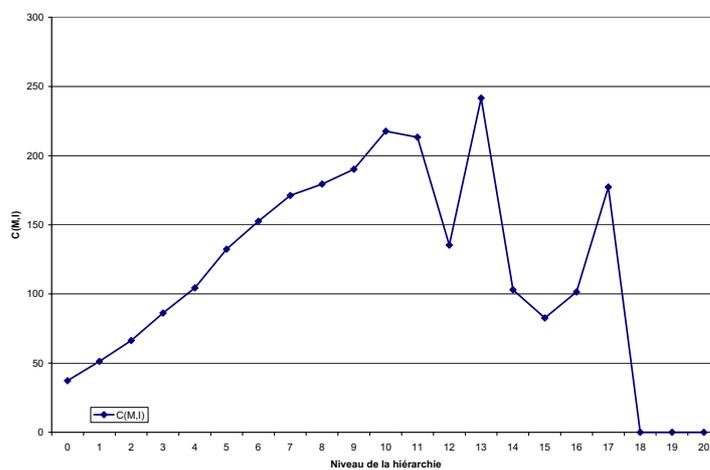
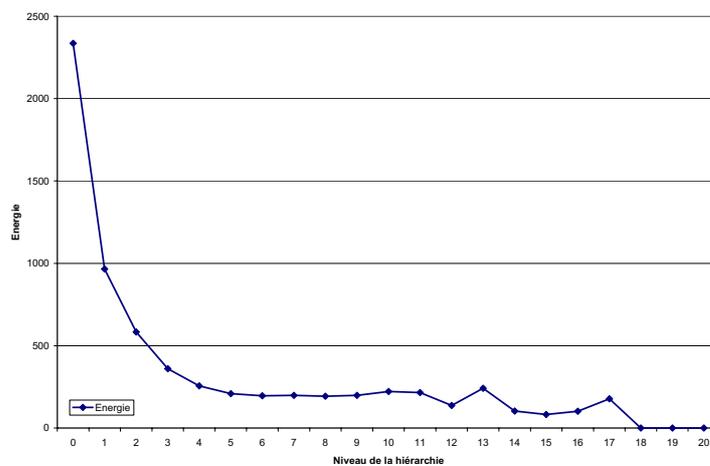
où R_i et R_j représentent les deux régions étudiées, $\bar{I}_{R_i}^C$ l'intensité moyenne de la région R_i pour la composante couleur C parmi les composantes X, Y, Z de l'espace de représentation couleur étudié ;

- la distance de Student entre deux régions R_i et R_j est définie comme suit :

$$d_{Student}(R_i, R_j) = \left(\frac{d_{euclidienne}(R_i, R_j)}{\left(\frac{n_i v_i + n_j v_j}{n_i + n_j - 2} \right)^{\frac{1}{2}} \times \left(\frac{n_i + n_j}{n_i \times n_j} \right)^{\frac{1}{2}}} \right)^2 \quad (7.8)$$

avec

$$v_i = \frac{1}{3} \left| \sum_{C \in X, Y, Z} \frac{1}{n_i} \left(\sum_{p \in R_i} I_{R_i}^C(p)^2 - \left(\frac{\sum_{p \in R_i} I_{R_i}^C(p)}{n_i} \right)^2 \right) \right|$$

(a) $D(M,I)$ (b) $C(M,I)$ 

(c) énergie

FIG. 7.14 – Variation des différents paramètres de l'énergie dans la production d'une hiérarchie.

où R_i et R_j représentent les deux régions étudiées, n_i et n_j respectivement le nombre de pixels des régions R_i et R_j , v_i et v_j les variances calculées pour les régions R_i et R_j . $I_{R_i}^C(p)$ l'intensité de la composante C du point p de la région R_i , ceci pour les composantes X, Y, Z de l'espace de représentation couleur étudié ;

- la distance Earth Mover's Distance (EMD) calculant une distance entre deux histogrammes H_i et H_j de deux régions R_i et R_j est définie de la façon suivante :

$$d_{EMD}(H_i, H_j) = \min_f(\text{Cout}(H_i, H_j, f)) = \frac{\min_f(\text{Cout}(H_i, H_j, f))}{\min\left(\sum_{i \in C_i} H_i(i), \sum_{j \in C_j} H_j(j)\right)} \quad (7.9)$$

avec

$$\text{Cout}(H_i, H_j, f) = \sum_{i \in C_i} \sum_{j \in C_j} f_{ij} d_{ij}$$

et

$$\sum_{i \in C_i} \sum_{j \in C_j} f_{ij} = 1 = \min\left(\sum_{i \in C_i} H_i(i), \sum_{j \in C_j} H_j(j)\right)$$

et où H_i et H_j représentent respectivement deux histogrammes normalisés calculés sur des régions R_i et R_j définis sur des supports colorimétriques C_i et C_j . d_{ij} est une distance entre les couleurs i et j dans l'espace utilisé et f_{ij} une fonction représentant la masse transférée de la couleur i de R_i vers la couleur j de R_j . Il faut noter que cette distance est extrêmement lourde en temps de calcul ;

- la distance de Mahalanobis :

$$d_{Mahalanobis}(R_i, R_j) = \left((\bar{I}_{R_i} - \bar{I}_{R_j}) \Sigma^{-1} (\bar{I}_{R_i} - \bar{I}_{R_j})^T \right)^{\frac{1}{2}} \quad (7.10)$$

avec \bar{I}_{R_i} le vecteur couleur moyen de la région R_i et Σ la somme des matrices de covariance des régions R_i et R_j ;

- la distance de Hotteling, reprise par VANHAMEL ET AL. dans [VANHAM00] est définie comme suit :

$$d_{Hotteling}(R_i, R_j) = \frac{1}{3 \times (n_i + n_j + 2)} \frac{n_i n_j \left((\bar{I}_{R_i} - \bar{I}_{R_j}) \Sigma^{-1} (\bar{I}_{R_i} - \bar{I}_{R_j})^T \right)^{\frac{1}{2}}}{n_i + n_j} \quad (7.11)$$

Les modèles de régions que nous avons retenus sont les suivants (on trouvera beaucoup plus de détails théoriques sur ces modèles dans [GUIGUE03A]) :

- le modèle constant de région : Dans le cas d'un modèle constant, l'erreur e_i^2 quantifiant l'erreur couleur moyenne de la région R_i se calcule de la façon suivante :

$$e_i^2 = \sum_{p \in R_i} \|X_p - \mu\|^2 = n_i \times T_r(V) \quad (7.12)$$

avec

$$V(k, l) = \frac{1}{n_i} \sum_{p \in R_i} (X_p^k - \mu^k)(X_p^l - \mu^l) \quad (7.13)$$

où X_p correspond au pixel p de la région R_i , n_i le nombre de pixels de la région R_i , V la matrice de variance/covariance des X_p , $T_r(V)$ la trace de la matrice. X_p^k et X_p^l représentent respectivement la j^{eme} et la l^{eme} composante couleur du pixel X_p . μ^k et μ^l correspondent respectivement à la moyenne des pixels de la composante k et de la composante l ;

- le modèle gaussien de région : Dans le cas d'un modèle gaussien, GUIGUES a montré que l'erreur e_i^2 quantifiant l'erreur couleur moyenne de la région R_i se calcule de la façon suivante [GUIGUE01, GUIGUE03A] :

$$e_i^2 = n_i \ln(\det V) = n_i \sum_{a=1}^3 3 \ln(\lambda_a) \quad (7.14)$$

où a représente les trois composantes de l'espace de représentation couleur utilisé et λ_a les valeurs propres de la matrice V .

La fonction d'énergie proposée permettant de quantifier la qualité d'une segmentation en vertu du principe de comparaison cité plus haut étant maintenant définie, nous pouvons l'utiliser pour déterminer automatiquement le niveau d'échelle d'une hiérarchie offrant la meilleure segmentation. Quelle que soit la méthode utilisée pour obtenir une hiérarchie de partitions, nous pouvons affirmer que le nombre de régions décroît au fur et à mesure que l'on progresse dans la hiérarchie. Nous cherchons alors un minimum local correspondant à une description simplifiée de l'image permettant un compromis entre la qualité de la segmentation et sa complexité. Procéder de cette façon nous permet de trouver rapidement et automatiquement le niveau d'une hiérarchie de partition offrant la meilleure segmentation au vue de la fonction d'énergie que nous avons définie.

Pour pouvoir déterminer les meilleurs paramètres de cette nouvelle fonction d'énergie, nous avons construit à titre d'exemple, une hiérarchie de partitions. Cette dernière présentée sur la figure 7.15 a été obtenue à partir de l'algorithme du waterfall reformulé dans [ANGULO03B]. Une étude des différents paramètres est ensuite présentée sur les figures 7.16 et 7.17 représentant respectivement la fonction d'énergie obtenue à chaque niveau de la hiérarchie selon une distance donnée avec un modèle gaussien ou un modèle constant. Nous remarquons rapidement que l'allure des différentes courbes est relativement proche. Un premier minimum local est obtenu au 6^{eme} ou 7^{eme} niveau de la hiérarchie suivant la distance que l'on utilise. Un premier maximum est ensuite obtenu au 12^{eme} niveau suivi d'un deuxième minimum au niveau 15. La distance euclidienne n'apporte pas de résultats satisfaisants, ce qui était prévisible du fait de son calcul simpliste effectué sur les régions. Les allures des autres courbes étant identiques à un niveau près, nous privilégions celle qui offre la plus grande amplitude c'est à dire la distance de Mahalanobis. La définition de notre fonction d'énergie imposant la recherche du premier minimum local, nous garderons le 6^{eme} niveau comme étant le meilleur niveau de segmentation. Une étude visuelle permet aussi de remarquer que les régions du « perroquet jaune » sont mal délimitées après

le niveau 6 de la hiérarchie. Les mêmes conclusions sont données pour le modèle constant présenté sur la figure 7.17. La différence entre ces deux modèles n'est pas visible sur ces figures puisque pour des raisons de lisibilité, nous avons illustré la hiérarchie de partitions seulement à partir du niveau 5, or il s'avère que la légère différence intervenait dans les deux premiers niveaux de la hiérarchie. Le modèle constant n'apportant pas d'avantage significatif par rapport au modèle gaussien, nous choisissons le modèle gaussien comme modèle de référence (mais nous aurions pu tout autant choisir le modèle constant comme modèle de référence).

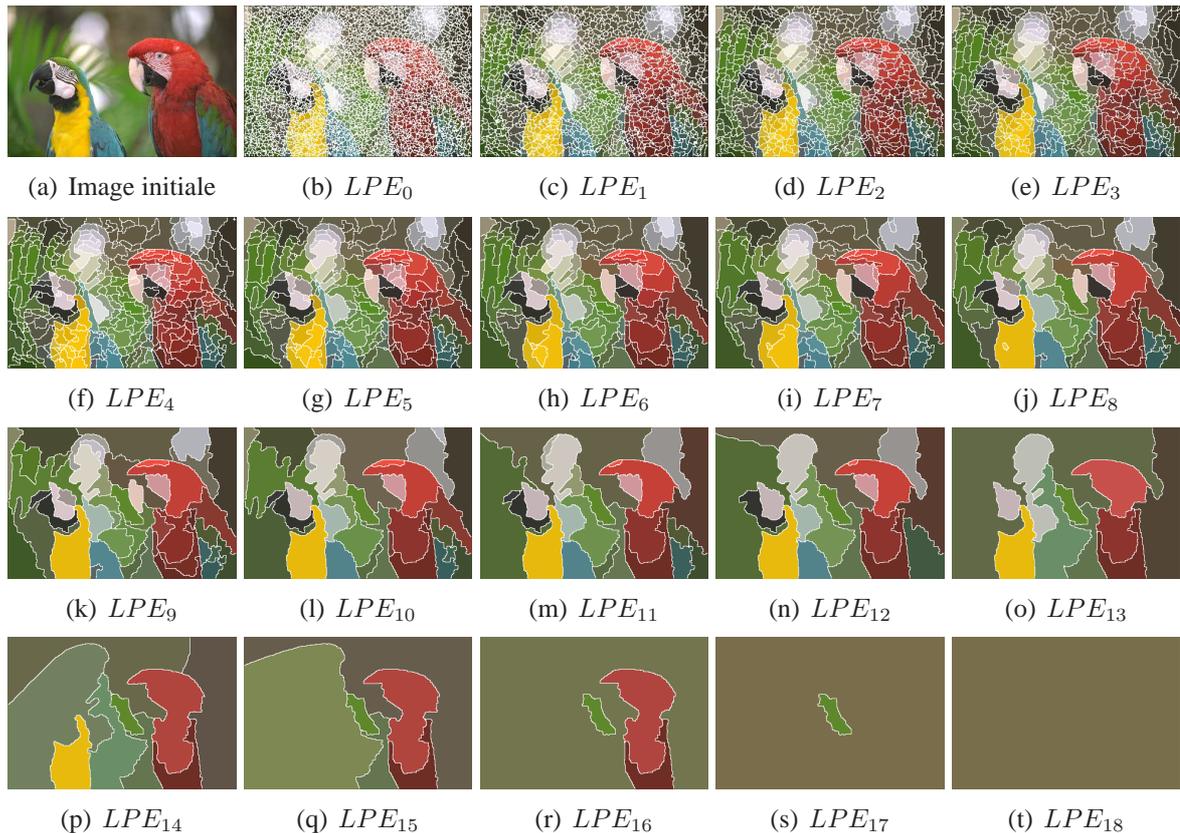


FIG. 7.15 – Hiérarchie de partitions obtenue avec l'approche par classique du waterfall (niveaux 0 à 18).

La distance de Mahalanobis et le modèle gaussien étant les paramètres définis par défauts, nous allons maintenant vérifier la compatibilité de notre fonction d'énergie avec ces derniers sur les différentes méthodes que nous avons proposées dans ce chapitre à savoir : une segmentation d'image par waterfall avec un nouveau gradient morphologique couleur, une simplification et segmentation d'image par lissage non linéaire d'un graphe et fusion de régions, une segmentation basée sur le nouveau critère connectif appelé zones homogènes et une segmentation par zones homogènes hiérarchiques. Les résultats de ces évaluations sont illustrés sur les figures 7.18 et 7.19. La fonction d'énergie calculée sur la hiérarchie de partitions obtenue par l'algorithme du waterfall avec une approche par graphe et une distance de norme L_1 (figure 7.18(a)) présente un minimum local au 6^{ème} niveau de la hiérarchie. Il en est de même pour la hiérarchie produite par un lissage non linéaire d'un graphe et fusion de régions avec un seuil évolutif et opérant directement sur le graphe d'une partition fine obtenue à partir des zones homogènes de niveau $k = 1$ (figure 7.18(b)). La fonction d'énergie sur les zones homogènes (figure 7.19(a)) possède

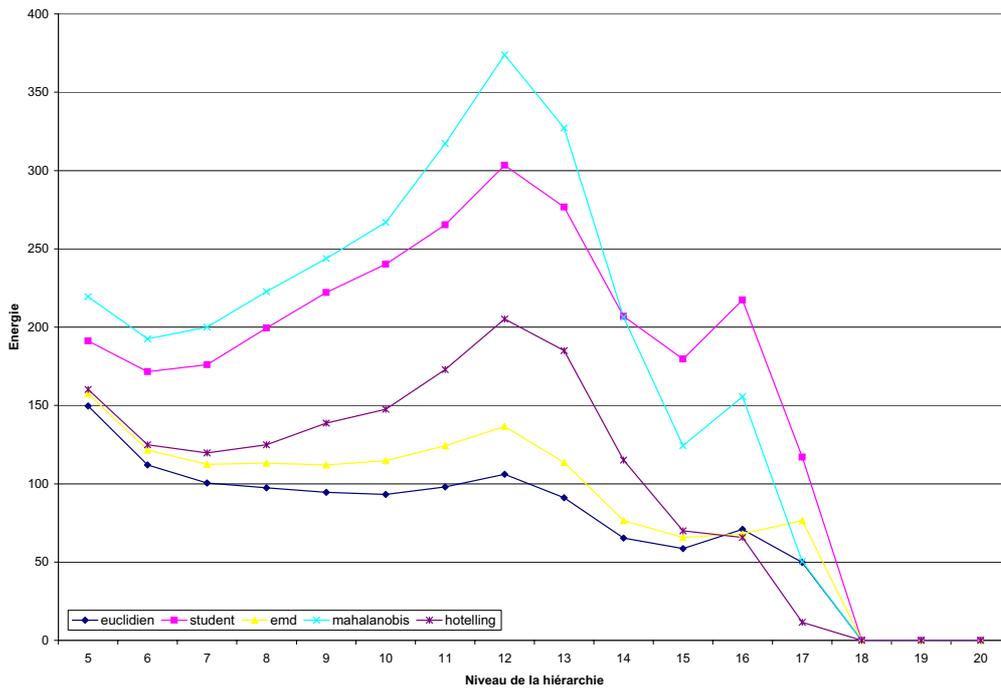


FIG. 7.16 – Influence du choix de la distance dans la mesure d'énergie pour l'évaluation d'une hiérarchie de partitions produite par waterfall (modèle gaussien).

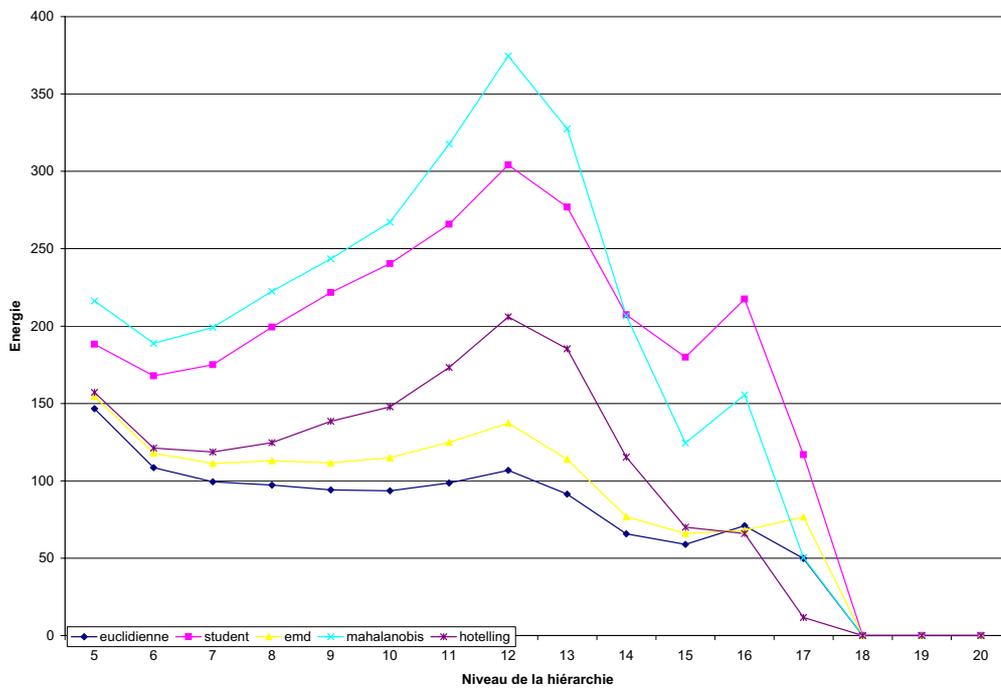


FIG. 7.17 – Influence du choix de la distance dans la mesure d'énergie pour l'évaluation d'une hiérarchie de partitions produite par waterfall (modèle constant).

un minimum local au 3^{ème} niveau et l'on voit par l'allure de la courbe que notre méthode d'évaluation n'est valide que dans le cadre de hiérarchies stratifiées. La figure 7.19(b) illustre une hiérarchie de partitions obtenue par les zones homogènes stratifiées, nous y trouvons d'ailleurs un minimum local au niveau 2. Tous ces résultats montrent que la nouvelle fonction d'énergie proposée permet bien de définir, quand il existe, le meilleur niveau d'une hiérarchie de partitions offrant le meilleur compromis entre la qualité de la segmentation et sa complexité.

7.5 Simplification d'une partition par fusion de régions

Nous venons de présenter ci-dessus une nouvelle fonction d'énergie offrant une évaluation de la qualité d'une segmentation d'images couleur dans le cadre d'une hiérarchie de partition. Mais cette énergie peut être utilisée dans un but de fusion de régions en l'utilisant comme critère de terminaison. En effet, Il suffit pour cela de fusionner deux à deux les régions de l'image jusqu'à l'obtention d'un minimum local de la fonction d'énergie. Nous proposons dans ce cadre une nouvelle méthode de fusion de régions. Nous présentons les trois points importants de cet algorithme à savoir le modèle de région, l'ordre de fusion et le critère de terminaison :

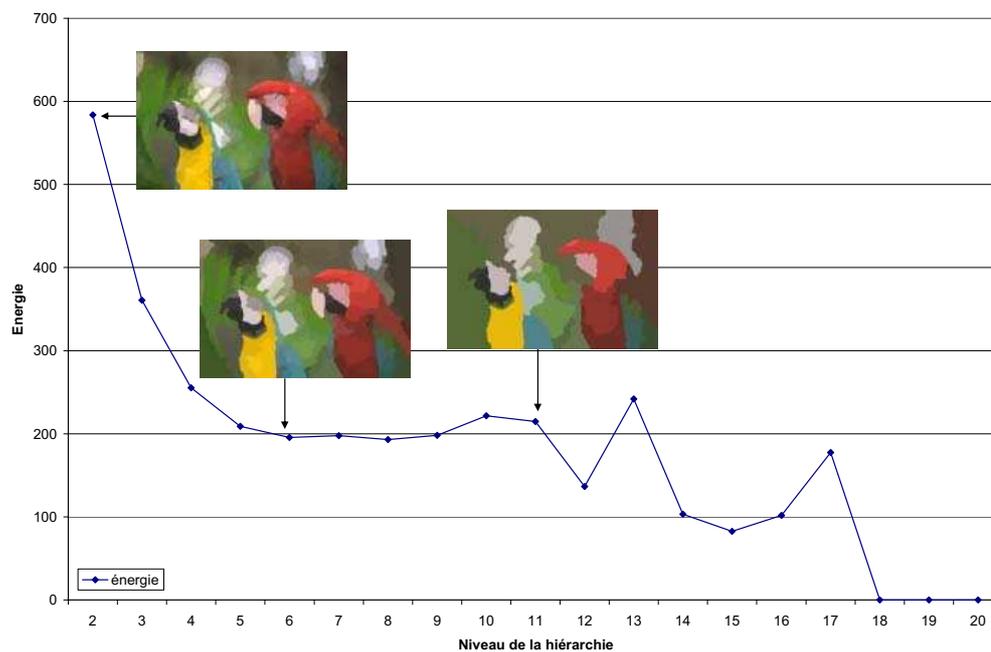
1. Le modèle de région $M(R)$ correspond à la somme des descripteurs des deux régions R_i et R_j c'est à dire $M(R) = M(R_i) + M(R_j)$;
2. L'ordre de fusion est défini comme étant :

$$O(R_i, R_j) = N_i [d(R_i, R_i \cup R_j) + (e_{R_i \cup R_j} - e_{R_i})] + N_j [d(R_j, R_i \cup R_j) + (e_{R_i \cup R_j} - e_{R_j})]$$

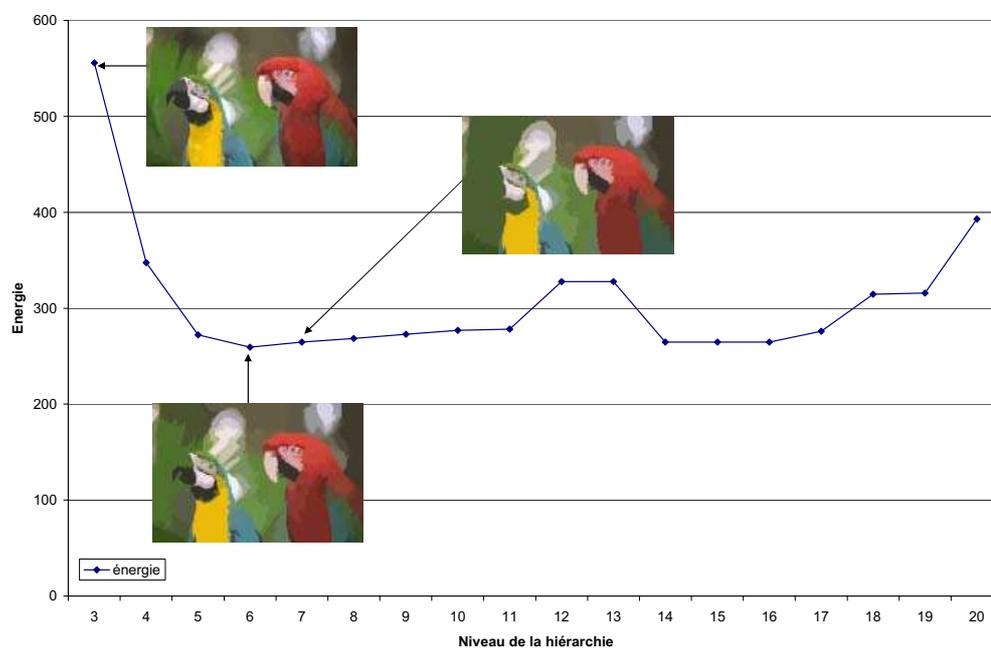
Cet ordre de fusion permet de fusionner en premier les régions qui, lorsqu'elles sont fusionnées avec une de leurs régions adjacentes, présentent peu de variations interne et externe. C'est à dire que la différence externe entre les modèles de région avant et après fusion est faible ainsi que la différence interne entre les régions avant et après fusion. Le choix de cet ordre de fusion est bien évidemment lié au fait que nous utilisons la fonction d'énergie de la section précédente ;

3. Le critère de terminaison correspond à l'obtention d'un minimum local de la fonction d'énergie que nous avons proposée à la section précédente.

Cette technique se trouve être intéressante pour simplifier par exemple une sur segmentation obtenue dans les premiers niveaux d'une hiérarchie de partitions effectuée par les zones quasi-plates, les connexions par sauts ou les zones homogènes. Elle peut être utilisée aussi pour extraire grossièrement et rapidement les principaux objets d'une image. On notera en outre que fusionner les régions deux à deux jusqu'à ce qu'un critère énergétique, basé sur des mesures liées aux noeuds du graphe, atteigne un minimum local, revient à chercher la première coupe minimale dans un arbre binaire de partitions. Les figures 7.20 et 7.21 présentent respectivement les résultats de la meilleure partition obtenue par fusion de région (utilisant comme critère de terminaison la nouvelle fonction d'énergie avec une métrique et un modèle donnés) selon une approche fonctionnant sur le graphe ou sur l'arbre de recouvrement minimum (MST). Quel que soit le modèle choisi, les partitions obtenues avec la distance Euclidienne et de Student ne sont pas très intéressantes car elles sont encore sur-segmentées. La distance de Mahalanobis est celle qui donne les résultats

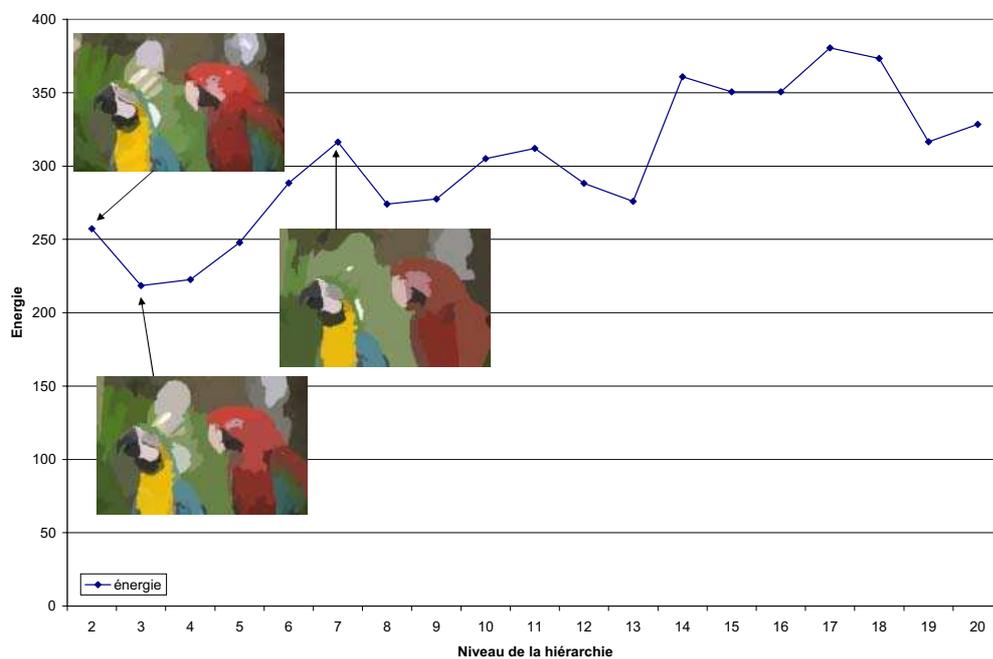


(a) Waterfall sur graphe

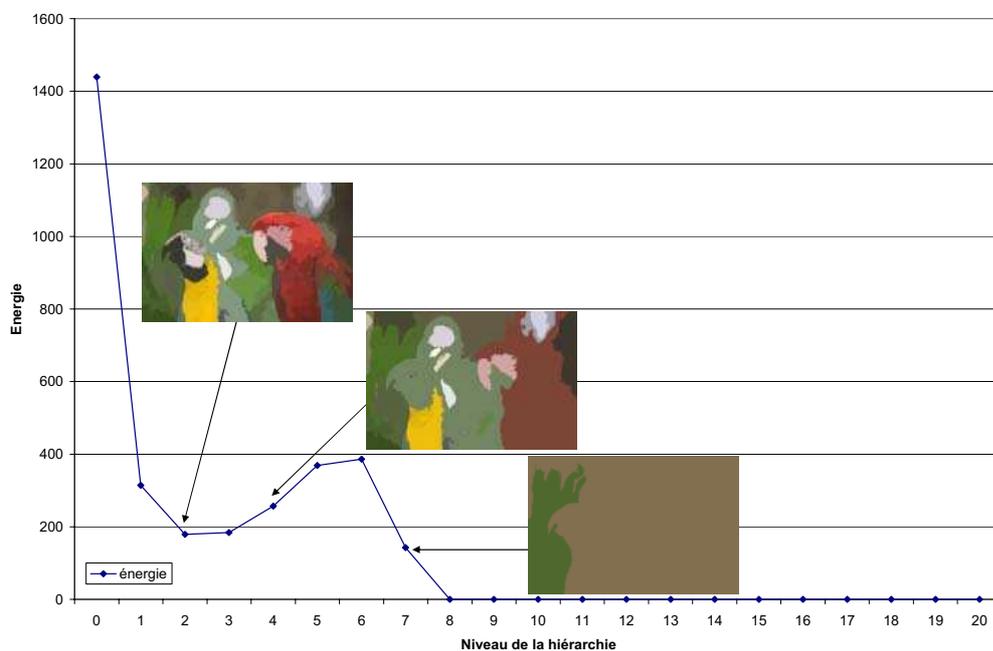


(b) Simplification et fusion du graphe

FIG. 7.18 – Application de la méthode d'évaluation sur une hiérarchie de partitions produite par deux des approches proposées : le waterfall avec une approche par graphe et un lissage non linéaire d'un graphe et fusion de régions.



(a) Zones homogènes



(b) Zones homogènes stratifiées

FIG. 7.19 – Application de la méthode d'évaluation sur une hiérarchie de partitions produite par deux des approches proposées : les zones homogènes non stratifiées et stratifiées.

les plus intéressants en terme de simplification et surtout pour le modèle gaussien, néanmoins dans le cadre d'une approche par graphe et d'un modèle constant, la qualité de la simplification de l'image est fortement diminuée. Nous pouvons par exemple nous rendre compte de la perte de certaines zones importantes de l'image comme « le bec du perroquet jaune ». Les distances EMD et Hotelling fournissent quant à elles des résultats intermédiaires. Notons que l'utilisation de l'approche par MST en comparaison avec l'approche par graphe est plus rapide en temps de traitement et offre une simplification plus fine mais avec un nombre de régions plus important et donc encore un peu trop sur-segmentée.

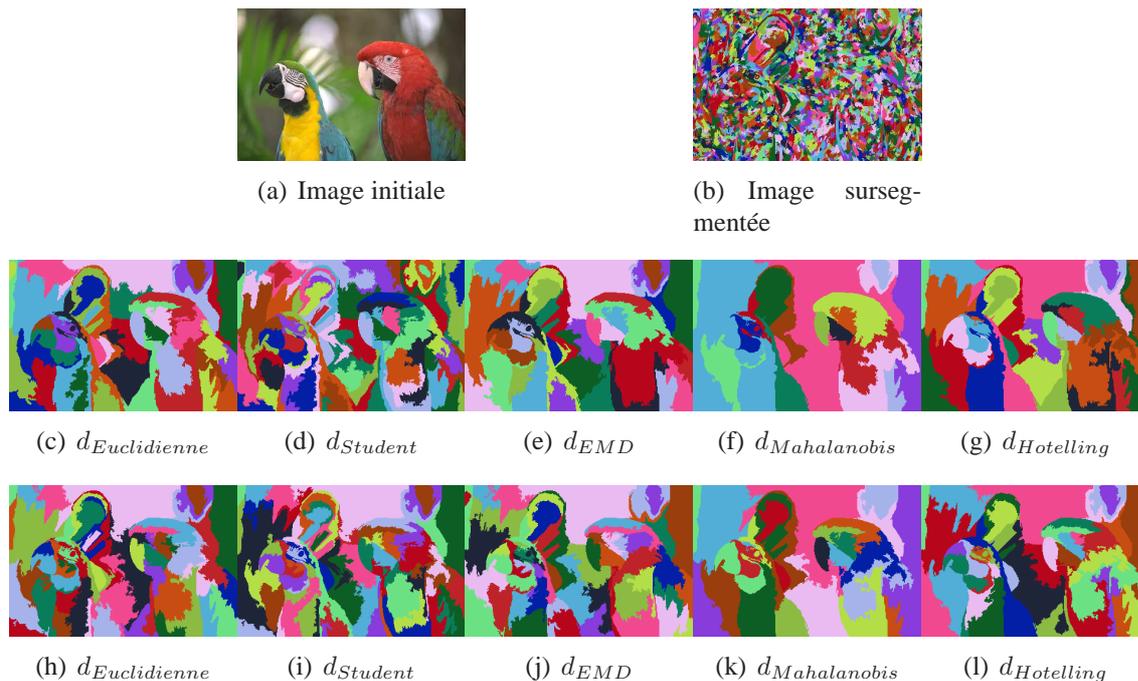


FIG. 7.20 – Détermination de la meilleure partition obtenue par fusion de régions par rapport à une distance inter-classe et un modèle (constant (c-g) ou gaussien (h-l)) et une approche par graphe.

7.6 Berkeley Segmentation Dataset and Benchmark

Nous illustrons plusieurs méthodes de segmentation d'images couleur présentées dans ce chapitre sur des images de la « Berkeley Segmentation Dataset and Benchmark (BSDB) ». Le but recherché ici est d'effectuer diverses combinaisons de nos méthodes et de montrer que quelque soit l'agencement effectué, nous obtenons des segmentations satisfaisantes. Cette base disponible sur Internet [BERKEL] regroupe un grand nombre d'images (en niveaux de gris ou couleur) et dispose de segmentations de référence produites par plusieurs experts. Cette base devient de plus en plus utilisée dans le domaine du traitement d'images (compression, segmentation, indexation) car elle peut permettre non seulement de tester des algorithmes par rapport à une segmentation de référence, mais aussi de pouvoir comparer les performances de méthodes de segmentation proposées dans la littérature sur des images identiques. Nous avons cherché à montrer ici que quelque soit l'ajancement

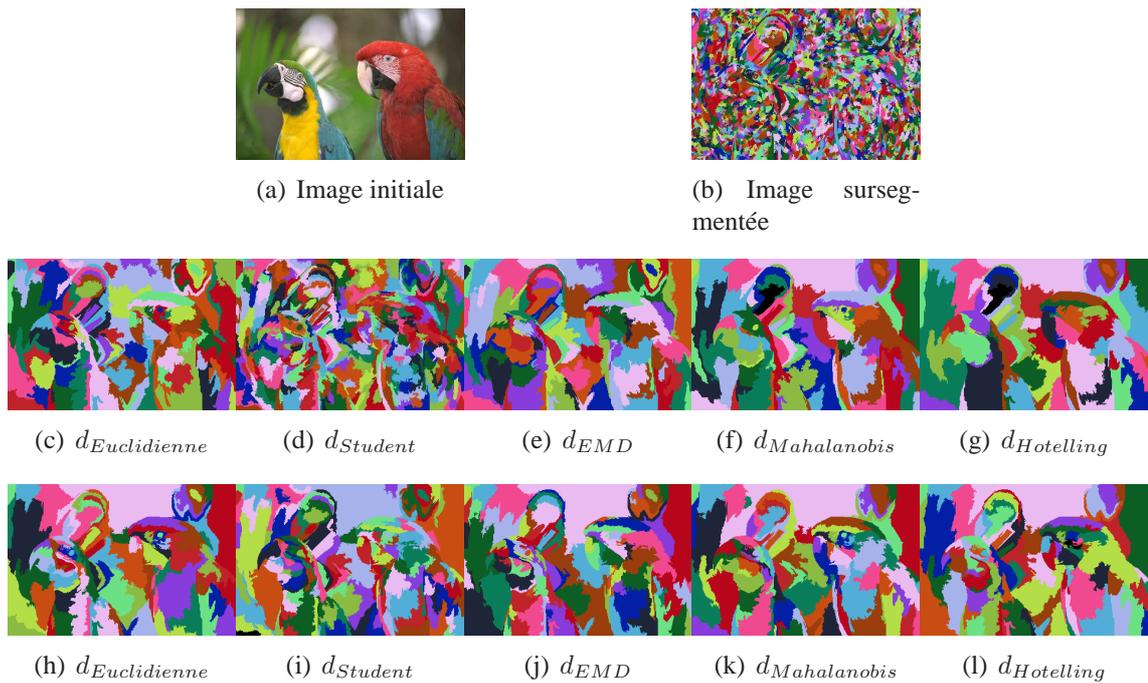


FIG. 7.21 – Détermination de la meilleure partition obtenue par fusion de régions par rapport à une distance inter-classe et un modèle (constant (c-g) ou gaussien (h-l)) et une approche par arbre de recouvrement minimum.

effectué, nous obtenons des segmentations assez satisfaisantes.

Les figures 7.22 et 7.23 illustrent les résultats de segmentation obtenus selon cinq approches que nous appelons par la suite « méthode 1 » à « méthode 5 » afin de pouvoir les identifier facilement.

1. « la méthode 1 » consiste tout d'abord à construire une hiérarchie de partitions par une Ligne de Partage des Eaux avec l'algorithme du waterfall (utilisant un gradient couleur lexicographique). Le meilleur niveau de la hiérarchie de partition ainsi produite est déterminé à l'aide de la fonction d'énergie proposée (utilisant un modèle gaussien et la distance de mahalanobis). Une fusion de régions (avec un critère de terminaison utilisant un modèle gaussien et une distance EMD) de l'image segmentée est ensuite réalisée ;
2. « la méthode 2 » consiste à construire une hiérarchie de partitions par une Ligne de Partage des Eaux avec l'algorithme du waterfall (utilisant une approche par graphe). Le meilleur niveau de la hiérarchie de partition ainsi produite est ensuite déterminé à l'aide de la fonction d'énergie proposée (utilisant un modèle gaussien et une distance de mahalanobis). Une fusion de régions (avec un critère de terminaison utilisant un modèle gaussien et la distance de Mahalanobis) de l'image segmentée est ensuite réalisée ;
3. « la méthode 3 » consiste dans un premier temps à construire une partition fine de l'image par la méthode des zones homogènes non stratifiées (de finesse égale à 1). Puis d'effectuer une segmentation de l'image par lissage non linéaire d'un graphe et fusion de régions (avec un seuil évolutif) dans le cadre d'une hiérarchie de partitions.

Et enfin de déterminer le meilleur niveau de la hiérarchie par la fonction d'énergie proposée (utilisant un modèle gaussien et la distance de mahalanobis) ;

4. « la méthode 4 » consiste à créer une partition fine par la méthode des zones homogènes non stratifiées (de finesse égale à 1.75). Puis d'effectuer une fusion de régions (avec un critère de terminaison utilisant un modèle gaussien et la distance de Mahalanobis) ;
5. « la méthode 5 » consiste dans un premier temps à créer une hiérarchie de partitions par les zones homogènes stratifiées et d'effectuer une fusion de régions (avec un critère de terminaison utilisant un modèle gaussien et la distance de Mahalanobis) sur l'image de niveau 6.

Aux vues de ces illustrations, nous pouvons dire que d'un point de vue général, les différentes méthodes proposées dans ce chapitre fournissent des segmentations très satisfaisantes.

7.7 Conclusion

Dans ce chapitre, nous avons dans un premier temps présenté un nouveau critère connectif nommé zones homogènes qui permet d'obtenir des partitions de finesse variables ainsi que des hiérarchies stratifiées. Dans un deuxième temps, nous avons proposé une nouvelle approche de la morphologie mathématique couleur basée sur les graphes et plus précisément sur la décimation de l'arbre de recouvrement minimum du Graphe d'Adjacence de Régions pour un élément structurant donné. Cette approche nous a permis de trouver le supremum et l'infimum d'un ensemble de vecteurs de couleur en s'affranchissant des défauts de l'ordre lexicographique classique. De ce fait, nous avons pu adapter correctement à la couleur les principales opérations de morphologie mathématique comme l'érosion et la dilatation ou des opérations plus complexes comme la segmentation par waterfall avec un gradient couleur défini par cette nouvelle approche. Puis, nous avons proposé une méthode pour la production d'une hiérarchie de partitions en combinant un lissage sur graphe d'adjacence de régions avec une décimation de graphe. L'approche consiste tout d'abord à définir une partition initiale considérée comme une partition fine qui constitue la base de la hiérarchie de partitions. Cette partition fine est décimée itérativement en alternant une simplification du graphe d'adjacence par un filtrage non linéaire opérant directement sur le graphe avec une fusion des régions similaires selon un critère de similarité défini par le niveau de la hiérarchie. L'approche proposée permet de construire de très bonnes simplifications d'image pour les niveaux inférieurs de la hiérarchie mais également d'obtenir des segmentations efficaces dans les niveaux supérieurs de la hiérarchie.

Pour finir, nous avons proposé une nouvelle fonction d'évaluation de la qualité d'une segmentation basée sur un compromis entre la qualité de la segmentation et la complexité du modèle. La minimisation de cette énergie permet d'obtenir de très bons résultats dans la définition du meilleur niveau d'une hiérarchie de partitions ou dans la simplification d'une segmentation par fusion de régions utilisant cette minimisation d'énergie comme critère de terminaison.

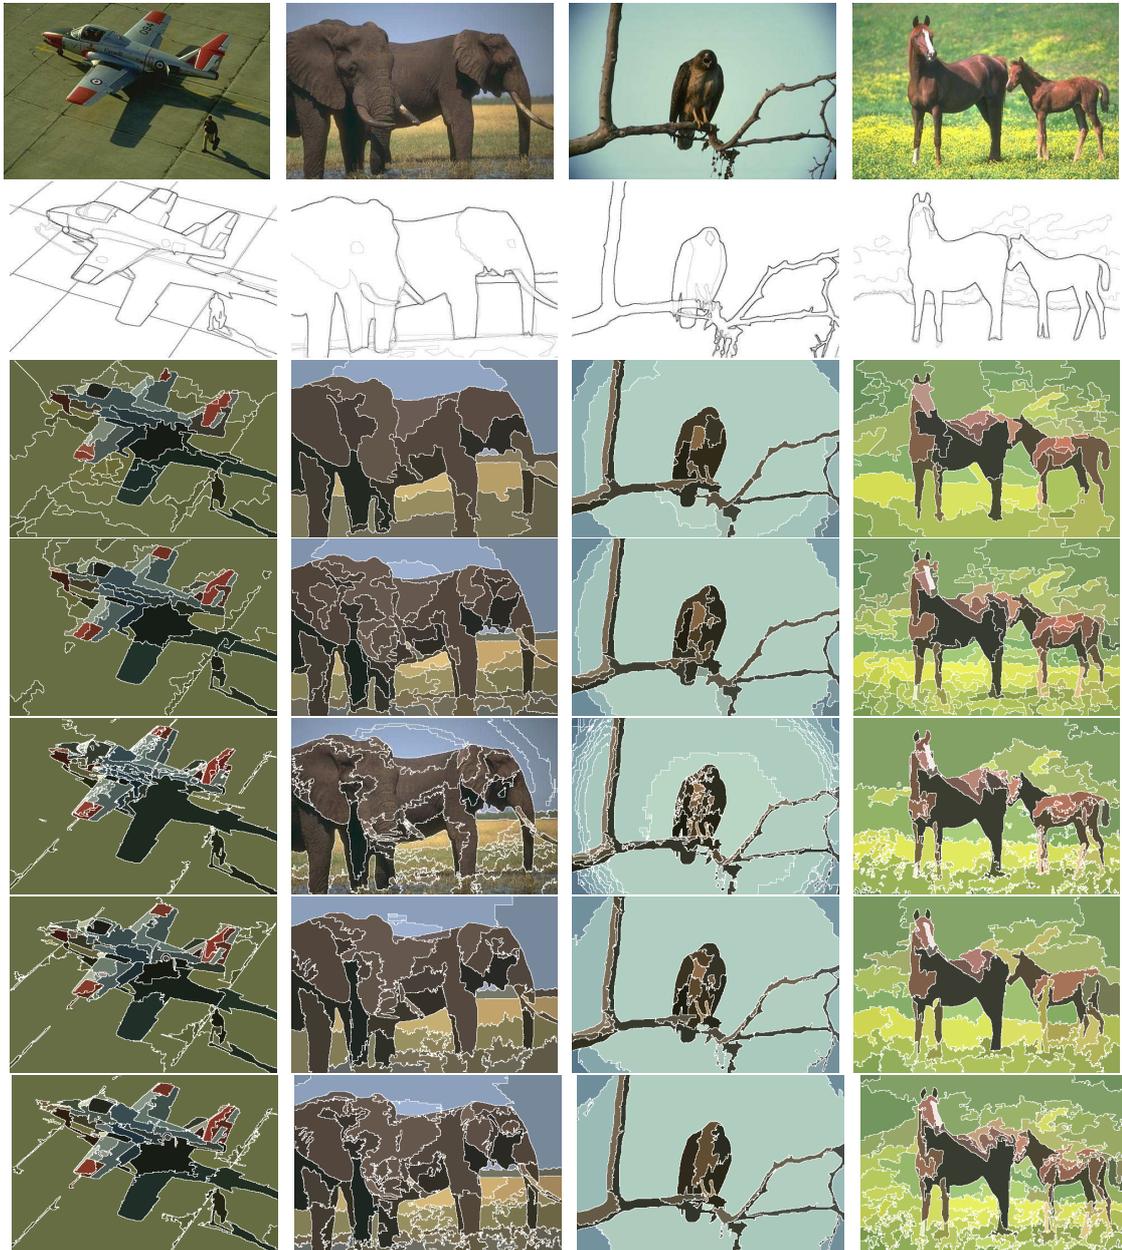


FIG. 7.22 – Résultats de cinq méthodes de segmentation sur une première série d'images de la BSD3 (de haut en bas : l'image initiale, la segmentation de référence et cinq méthodes de segmentation que nous avons précédemment identifiées sous le nom de « méthode 1 » à « méthode 5 »).

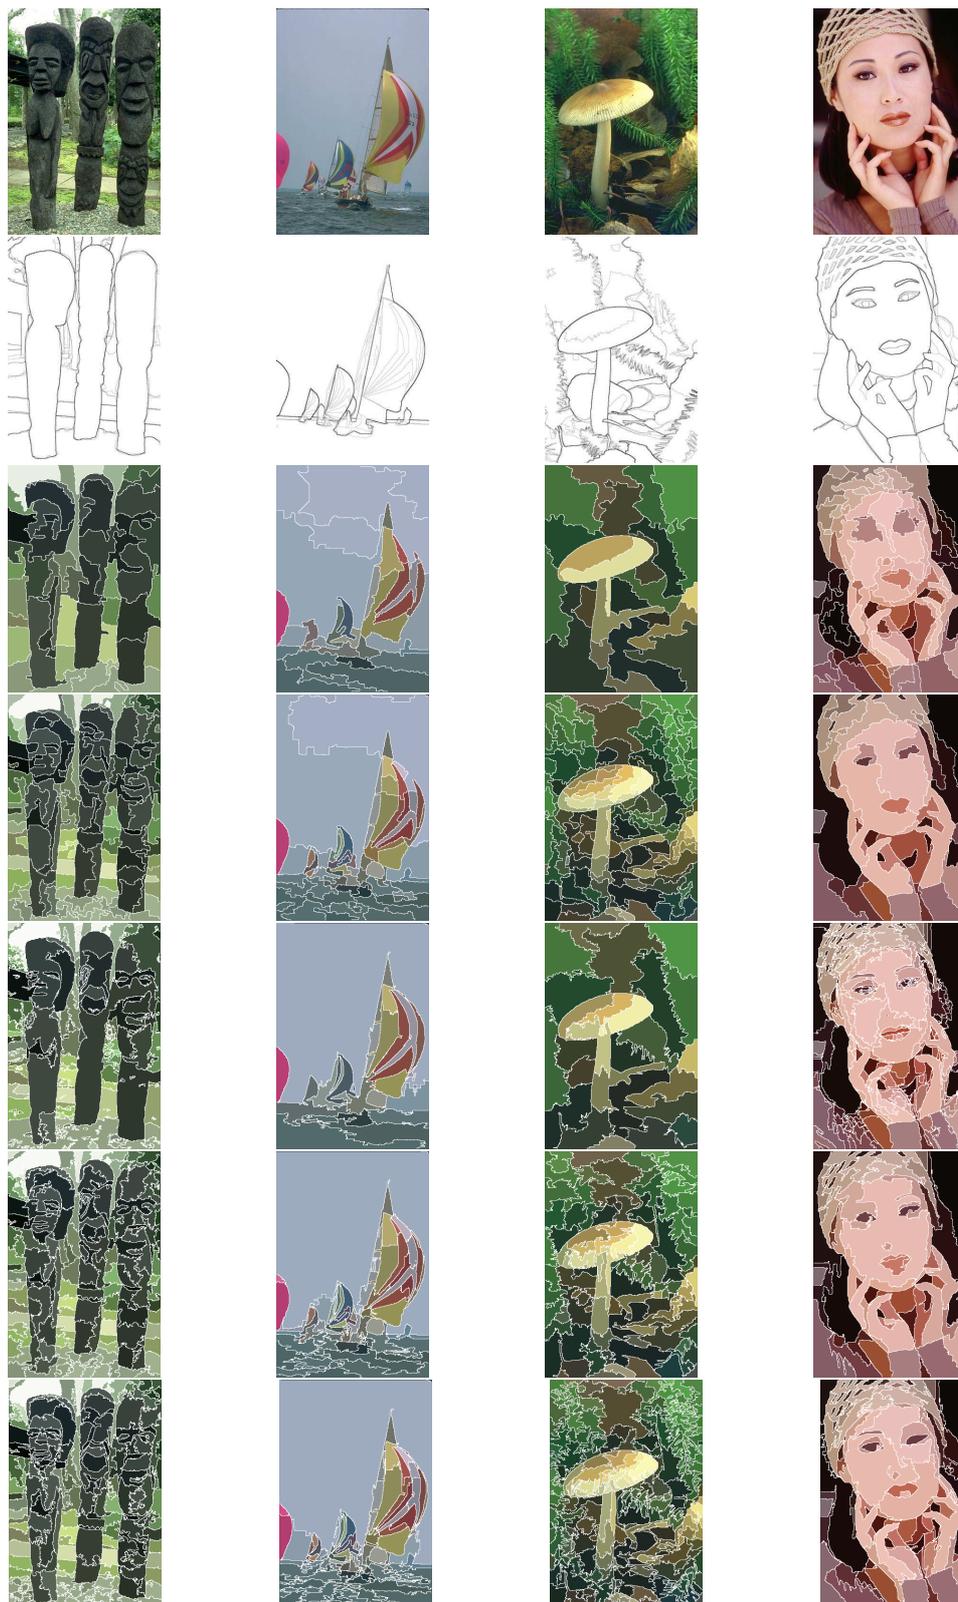


FIG. 7.23 – Résultats de cinq méthodes de segmentation sur une deuxième série d'images de la BSDB (de haut en bas : l'image initiale, la segmentation de référence et cinq méthodes de segmentation que nous avons précédemment identifiées sous le nom de « méthode 1 » à « méthode 5 »).

CONCLUSION GÉNÉRALE ET PERSPECTIVES

Apports de cette thèse

Dans cette thèse, nous avons étudié différentes approches de segmentation d'images couleurs. Dans une première partie, nous nous sommes intéressés à développer une stratégie de segmentation d'images microscopiques pouvant contribuer à l'amélioration de l'étape de segmentation d'une station d'analyse de microscopie automatisée pour la cytopathologie afin d'améliorer le contrôle qualité en imagerie microscopique pour la santé. Dans une deuxième partie, nous nous sommes intéressés à développer des méthodes de segmentation d'images couleur d'un point de vue général, pouvant être vues comme une hiérarchie de partitions représentant l'image à différents niveaux et appliquées pour des problèmes particuliers en indexation d'images, en vidéo, etc.

Dans un premier temps, nous avons proposé une approche hybride de segmentation d'images couleur. Chacune des étapes a été détaillée dans le cadre de la problématique de segmentation d'images microscopiques et illustrée sur des images de cytologie bronchique. La difficulté de la segmentation réside dans le fait que les cellules (composées d'un cytoplasme et d'un noyau) sont récoltées dans un contexte très mucoïde (présence de mucus considéré comme un objet indésirable), celui-ci ayant le même aspect que certaines cellules. Nous avons tout d'abord présenté deux approches de classification pixellaire non supervisée que nous avons nommée « classification pixellaire non supervisée en une étape » et « classification pixellaire non supervisée en deux étapes ». Nous avons montré que cette dernière fournissait de meilleurs résultats qu'une classification pixellaire classique. L'importance du choix de l'espace couleur a elle aussi été prouvée. L'utilisation de l'approche proposée ainsi que des méthodes de classification pixellaire supervisées (utilisant une segmentation de référence établie par des experts en cytopathologie) nous a amené à conclure que l'algorithme des k-moyennes et des Machines à Support de Vecteurs (SVM) utilisés dans l'espace YCh_1Ch_2 donnaient les meilleurs résultats. L'utilisation de plusieurs classifieurs entraînant des conflits de décisions, nous avons exploité la complémentarité qu'il peut exister entre eux et avons proposé une méthode de combinaison de classifications pixellaires prenant en compte l'information de voisinage (jusqu'à 64 voisins) et le nombre de classifieurs combinés (jusqu'à 8 classifieurs). Les résultats ont permis de montrer que l'utilisation d'une combinaison des trois meilleurs classifieurs (k-moyennes, SVM et Bayes) en tenant compte de l'information de huit voisins améliore les résultats de classification par rapport à une classification pixellaire seule. Une intégra-

tion dans une approche morphologique basée sur une Ligne de Partage des Eaux a permis d'augmenter définitivement nos résultats. Ces résultats ont pu être établis par la définition d'une nouvelle méthode d'évaluation de la qualité de la segmentation adaptée à la cytologie.

Dans un deuxième temps, nous nous sommes intéressés aux méthodes de segmentations hiérarchiques. Nous avons tout d'abord présenté un critère connectif que nous avons nommé « zones homogènes », qui est une variation des connexions par cheminements et des connexions par seuil. Ce critère produit des partitions qui respectent bien les contours des objets et permet d'obtenir des partitions de finesses variables ainsi que des hiérarchies stratifiées. Nous nous sommes par la suite intéressés à l'application de la morphologie mathématique aux images couleur. Nous avons à ce titre proposé une approche de la morphologie mathématique basée sur les graphes permettant de déterminer le suprémum et l'infimum d'un ensemble de vecteurs couleur en s'affranchissant des défauts de l'ordre lexicographique classique. Par cette approche, nous pouvons par exemple montrer qu'une simple opération d'érosion permet à présent d'accentuer les contours d'une image de façon homogène et indépendamment des couleurs des différentes zones de celle-ci. Nous avons pu redéfinir ensuite l'algorithme du « waterfall » en utilisant différents gradients couleur définis par cette approche et non plus par l'approche classique d'ordre lexicographique. Nous avons de ce fait montré que la hiérarchie de partitions produites est plus lisse et que les meilleurs résultats sont obtenus avec un gradient de norme L_1 . Nous avons ensuite proposé une approche de création d'une hiérarchie de partitions combinant un lissage sur graphe d'adjacence de régions avec une décimation du graphe. Cette approche a montré qu'elle permettait d'obtenir de bonnes simplifications de l'image dans les bas niveaux de la hiérarchie mais aussi de très bonnes segmentations dans les niveaux supérieurs. Enfin nous avons proposé une méthode d'évaluation de la qualité d'une segmentation que nous avons pu utiliser pour trouver le meilleur niveau d'une hiérarchie de partitions ou bien comme critère de terminaison dans un processus de fusion de régions par descente d'énergie. Cette énergie est constituée de deux termes qui sont l'attache aux données et la complexité du modèle faisant intervenir respectivement un modèle de région et une distance entre régions. Les paramètres retenus pour cette méthode sont le modèle gaussien et la distance de Mahalanobis. La minimisation de cette fonction d'énergie et l'obtention du premier minimum local nous permet de trouver le meilleur niveau d'une hiérarchie de partitions offrant un bon compromis entre attache aux données et complexité du modèle, et ce quelque soit la méthode de production de la hiérarchie de partitions utilisée.

Perspectives

Différents résultats de cette thèse permettent d'envisager des poursuites de travaux de recherche :

En ce qui concerne la première partie correspondant à la segmentation d'images couleur par classification pixellaire, nous envisageons d'améliorer l'étape de fusion de classifieurs en fusionnant les résultats d'un même classifieur dans différents espaces de représentation couleur ou en prenant en compte une probabilité de classification fournie par le

classifieur à la place d'une décision dure de type classe comme c'est le cas actuellement. Des travaux parallèles utilisant cette approche ont été effectués par LEBRUN [LEBRUN05] dans le cadre des SVM. Une autre perspective consisterait à classifier des régions et non plus des pixels. Pour ce faire, nous pourrions construire une partition fine et classifier les régions en intégrant des critères tels que la texture qui correspondent à la deuxième source d'information après la couleur sur des images microscopiques de cytologie bronchiques. Enfin, nous envisageons d'étendre notre stratégie de segmentation à différents types de cytologies comme par exemple la cytologie des séreuses, urinaire, gynécologiques, etc.

En ce qui concerne la deuxième partie sur la segmentation d'images couleur par hiérarchie de partitions, nous envisageons de réfléchir sur l'utilisation de l'approche par graphe en morphologie mathématique couleur, pour définir un ordre total dans la construction d'un treillis complet des couleurs d'un élément structurant. Ceci pourrait apporter un intérêt pour des opérateurs de morphologie mathématique comme les nivellements. Nous envisageons aussi d'étudier l'influence de l'espace couleur sur la qualité d'une hiérarchie de partitions produite par les algorithmes proposés. Pour terminer, nous souhaitons adapter notre fonction d'énergie pour prendre en compte en plus de l'attache aux données et de la complexité du modèle, un terme de rapidité faisant intervenir le temps de traitement nécessaire pour la construction d'un niveau de la hiérarchie. Ce nouveau terme peut s'avérer utile dans des domaines d'applications tels que la vidéo, le temps réel, les flux de données importants.

PUBLICATIONS DE L'AUTEUR

Reuves internationales

1. Combination of multiple pixel classifiers for microscopic image segmentation.
C. Meurie, O. Lezoray, C. Charrier, A. Elmoataz
IASTED International Journal of Robotics and Automation, Special issue on Colour Image Processing and Analysis for Machine Vision, ISSN 0826-8185, Issue 2, Vol.20, pp.63-69, 2005.
2. A comparison of supervised pixels-based color image segmentation methods. Application in cancerology.
C. Meurie, G. Lebrun, O. Lezoray, A. Elmoataz
WSEAS Transactions on Computers, ISSN 1109-2750, Issue 3, Vol.2, pp.739-744, July 2003.

Communications internationales avec actes et comité de lecture

1. A graph approach to color mathematical morphology.
O. Lezoray, C. Meurie, A. Elmoataz
IEEE International Symposium on Signal Processing and Information Technology, December 2005 (Accepté).
2. Fast pixel classification by SVM using Vector Quantization, Tabu Search and hybrid Color Space.
G. Lebrun, C. Charrier, O. Lezoray, C. Meurie, H. Cardot
International Conference on Computer Analysis of Images and Patterns, Vol.LNCS 3691, pp.685-692, France, Septembre 2005.
3. Multiple pixel classifier combination for bronchial tumors image segmentation.
C. Meurie, O. Lezoray, A. Elmoataz
IEEE International Conference on Complex Systems Intelligence and Modern technological Applications, Special Session, Vol.1, pp. 305-310, France, September 2004.

4. A supervised segmentation scheme for cancerology color images.
C. Meurie, G. Lebrun, O. Lezoray, A. Elmoataz
IEEE International Symposium on Signal Processing and Information Technology,
pp. 664-667, Germany, December 2003.
5. A comparison of supervised pixels-based color image segmentation methods. Application in cancerology.
C. Meurie, G. Lebrun, O. Lezoray, A. Elmoataz
WSEAS International Conference On Signal, Speech and Image Processing, Greece,
October 2003.
6. Comparaison de classifieurs non-supervisés pour la segmentation d'images couleur : Application en imagerie biomédicale.
C. Meurie, O. Lezoray, H. Cardot, A. Elmoataz
IAPR International Conference on Image and Signal Processing, Vol.1, pp. 30-37,
Morocco, June 2003.

Communications nationales avec actes et comité de lecture

1. Hiérarchie de partitions pour la simplification et la segmentation d'images couleur.
O. Lezoray, C. Meurie, P. Belhomme, A. Elmoataz
COMpression et REprésentation des Signaux Audiovisuels, pp. 231-236, Novembre 2005.
2. Classification rapide de pixels par SVM dans un espace couleur hybride.
G. Lebrun, C. Charrier, O. Lezoray, C. Meurie, H. Cardot
COMpression et REprésentation des Signaux Audiovisuels, pp. 301-306, Novembre 2005.

Exposés nationaux avec actes et sans comité de lecture

1. Superquartiques de Dupin joignant un superellipsoïde de révolution et un plan.
L. Garnier, C. Meurie, O. Lezoray
Groupe de Travail en Modélisation Géométrique, pp. 77-91, Poitiers, Mars 2005.
2. Segmentation d'images couleur par classification de pixels et morphologie mathématique.
C. Meurie, O. Lezoray, A. Elmoataz, M. Lecluse, H. Elie
27^{ème} journées de la section française de l'International Society for Stereology,
Paris, Février 2004.

3. Segmentation d'images couleur par fusion de classification de pixels. Application en imagerie biomédicale.
C. Meurie, O. Lezoray, A. Elmoataz
16^{ème} journées de l'Association Française d'Informatique Graphique, pp. 104-110, Paris, Décembre 2003.

4. Classification de pixels pour la segmentation d'images couleur : Application en cancérologie.
C. Meurie , O. Lezoray, H. Cardot, A. Elmoataz
Forum Jeunes Chercheurs, GDR-ISIS, Paris, Octobre 2002.

BIBLIOGRAPHIE

- [ALTUNB98] Y. ALTUNBASAK, P. EREN & A. TEKALP. « region-based motion segmentation using color segmentation ». Dans *Graphical Models and image Processing*, vol. 60, pages 13–23, 1998.
- [ANGULO03A] J. ANGULO. « Morphologie mathématique et indexation d’images couleur. Application à la microscopie en biomédecine ». Thèse de doctorat, Centre de Morphologie Mathématique, Ecole des Mines de Paris, Décembre 2003.
- [ANGULO03B] J. ANGULO & J. SERRA. « Color segmentation by ordered mergings ». Dans *Proc. of ICIP 2003*, vol. 2, pages 125–128, 2003.
- [ARBELA04] P. ARBELAEZ & L. COHEN. « Energy Partitions and Image Segmentation ». *Journal of Mathematical Imaging and Vision archive*, vol. 20, pages 43–57, 2004.
- [ASTOLA90] J. ASTOLA, P. HAAVISTO & Y. NEUVO. « Vector median Filters ». Dans *Proc. IEEE*, vol. 78, pages 678–689, 1990.
- [BALASU94] R. BALASUBRAMANIAN, J. ALLEBACH & C. BOUMAN. « Color image quantization with use of a fast binary splitting technique ». *Journal of optical Society of America*, 11(11), pages 2777–2786, 1994.
- [BARNET76] V. BARNETT. « The ordering of multivariate data ». *Journal of the royal society of statistics*, A 139(3), pages 318–355, 1976.
- [BERKEL] BERKELEY. « The Berkeley Segmentation Dataset and Benchmark ». à <http://www.cs.berkeley.edu/projects/vision/grouping/segbench/>.
- [BERTOL95] P. BERTOLINO. « Contribution de pyramides irrégulières en segmentation d’images multirésolution ». Thèse de doctorat, Institut National Polytechnique de Grenoble, Novembre 1995.
- [BEUCHE94] S. BEUCHER. « Watershed, hierarchical segmentation and waterfall algorithm ». *Mathematical Morphology adns its Applications to Image and Signal Processing*, pages 69–76, 1994.
- [BISTER90] M. BISTER, J. CORNELIS & A. ROSENFELD. « A critical view of pyramid segmentation algoritms ». *Pattern Recognition Letters*, 11(9), pages 605–617, 1990.
- [BORSOT98] M. BORSOTTI, P. CAMPADELLI & R. SCHETTINI. « Quantitative evaluation of color image segmentation results ». *Pattern Recognition Letters*, vol. 19, pages 741–747, 1998.
- [BOYKOV01] Y. BOYKOV, O. VEKSLER & R.ZABIH. « Fast approximation energy minimisation via graph cuts ». *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(11), pages 1222–1239, 2001.

- [BRUN00] L. BRUN, W. KROPATSCH & WALTER. « Irregular Pyramids with Combinatorial Maps ». Dans *Advances in Pattern Recognition, Joint IAPR International Workshops SSPR'2000 and SPR'2000*, vol. 1451, pages 256–265, 2000.
- [BRUN02] L. BRUN. « Traitement d'images couleur et pyramides combinatoires ». Habilitation à diriger des recherches, Université de Reims, 2002.
- [BRUN03] L. BRUN, WALTER & W. KROPATSCH. « Contraction Kernels and Combinatorial Maps ». *Pattern Recognition Letters*, 24(8), pages 1051–1057, 2003.
- [BURT83] P. BURT & E. ADELSON. « The laplacian pyramid as a compact image code ». *IEEE Transactions on Communications*, vol. 31, pages 532–540, 1983.
- [BURT84] P. BURT. « The pyramid as a structure for efficient computation, multi-resolution image processing and analysis ». *Multiresolution image processing and analysis*, pages 6–35, 1984. Springer : Berlin.
- [BUSIN04A] L. BUSIN, N. VANDENBROUCKE, L. MACAIRE & J. POSTAIRE. « Color space selection for unsupervised color image segmentation by analysis of connectedness properties ». Dans *Complex Systems Intelligence and Modern Technology Applications*, vol. 1, pages 311–322, 2004.
- [BUSIN04B] L. BUSIN, N. VANDENBROUCKE, L. MACAIRE & J. POSTAIRE. « Color space selection for unsupervised color image segmentation by analysis of connectedness properties ». *International Journal of robotics and automation*, vol. 1, pages 70–77, 2004.
- [CAILLO05] A. CAILLOT. « Calibration d'un ensemble microscope photonique et caméra couleur 3CCD pour la cytométrie par analyse d'images ». Rapport technique, Université de Caen, 2005. Rapport de stage de licence professionnelle Acquisition et Traitement d'Images.
- [CAMPAD97] P. CAMPADELLI, D. MEDICI & R. SCHETTINI. « color image segmentation using hopfield networks ». Dans *Image and Vision Computing*, vol. 15, page 161, 1997. (3).
- [CANU02] S. CANU. « Modèles connexionnistes et machines à vecteurs supports pour la décision ». R. Lengellé, Hermès, 2002. Chapitre du livre « Décision de reconnaissance des formes en Signal ».
- [CARRON95] T. CARRON. « Segmentation d'images couleur dans la base Teinte-Luminance-Saturation : approche numérique et symbolique ». Thèse de doctorat, Université de Savoie, Décembre 1995.
- [CELENK90] M. CELENK. « A color clustering technique for image segmentation ». Dans *Computer vision Graphics and Image Processing*, vol. 52, pages 145–170, 1990.
- [CELENK95] M. CELENK. « Analysis of color images of natural scenes ». *Journal of Electronic Imaging*, 4(4), pages 382–396, 1995.
- [CHABRI04] S. CHABRIER, B. EMILE, H. LAURENT, C. ROSENBERGER & P. MARCHÉ. « Unsupervised Evaluation of Image Segmentation Application to Multi-Spectral Images ». Dans *International Conference on Pattern Recognition*, vol. 1, pages 576–579, 2004.

- [CHABRI05] S. CHABRIER, C. ROSENBERGER & B. EMILE. « Evaluation de la performance de la segmentation d'images par fusion de critères ». Dans *ORASIS*, 2005.
- [CHANUS98] J. CHANUSSOT & P. LAMBERT. « Total ordering based on space filling curves for multivalued morphology ». Dans *Proceedings of the fourth international symposium on Mathematical morphology and its applications to image and signal processing*, pages 51–58, 1998.
- [CHARRI98] C. CHARRIER. « Vers l'optimisation statistique et perceptuelle de la qualité pour la compression des images couleur par quantification vectorielle ». Thèse de doctorat, Université Jean Monnet de Saint-Étienne, 1998.
- [CHASSE84] J. CHASSERY & C. GARBAY. « An iterative segmentation method based on contextual color and shape criterion ». *IEEE transactions on Pattern Analysis and Machine Intelligence*, 6(6), pages 794–800, 1984.
- [CHENG00] H. CHENG. « A hierarchical approach to color image segmentation using homogeneity ». *IEEE Trans on Image Processing*, 9(12), pages 2071–2082, Décembre 2000.
- [CHOU00] Y.-Y. CHOU & L. SHAPIRO. « A hierarchical multiple classifier learning algorithm ». Dans *ICPR*, vol. 2, pages 152–155, 2000.
- [CHRIST05] N. CHRISTIANINI. « Dimension reduction in text classification with support vector machines ». *JMLR*, vol. 6, pages 37–53, 2005.
- [CIE98] CIE. « The CIE Interim Colour Appearance Model CIECAM's ». Rapport technique 131, CIE Publication, 1998. Vienna.
- [CIE02] CIE. « A Color Appearance Model for Color Management Systems : CIECAM02 ». Rapport technique, 2002. CIE TC8-01, Draft No.9.
- [CLARAM84] G. CLARAMONT. « Développement de techniques de segmentation chromatique et implantation dans un module de vision ». Thèse de doctorat, Institut National Polytechnique de Toulouse, Décembre 1984.
- [COCQUE95] J. COCQUEREZ & S. PHILIPP. « Analyse d'images : filtrage et segmentation ». Paris : Masson, 1995.
- [COHEN89] L. COHEN, L. VINET, P. SANDER & A. GAGALOWISZ. « Hierarchical regional based stereo matching ». Dans *Computer Vision and Pattern Recognition*, pages 416–421, 1989.
- [COMER99] M. COMER & E. DELP. « Morphological operations for colour image processing ». *Journal of electronic imaging*, 8(3), pages 279–289, 1999.
- [CORSO04] J. CORSO, M. DEWAN & G. HAGER. « Image Segmentation Through Energy Minimization Based Subspace Fusion ». Dans *17th International Conference on Pattern Recognition*, 2004.
- [COUTAN91] V. COUTANCE. « La couleur en vision par ordinateur. Application à la robotique ». Thèse de doctorat, Université Paul Sabatier de Toulouse, Janvier 1991.
- [CRESPO94] J. CRESPO & R. SCHAFFER. « The flat zone approach and color image in Mathematical morphology and its application to image and signal processing ». pages 85–92, Kluwer, 1994.

- [CRISTI00] N. CRISTIANINI & J. . SHAWE-TAYLOR. « Introduction to Support Vector Machines and other kernel-based learning methods ». Cambridge University Press, 2000.
- [DARUGN04] J. DARUGNA. « De l’usage des méthodes bas niveaux pour la recherche d’images par le contenu ». Thèse de doctorat, Université Jean Monnet, Saint-Etienne, Décembre 2004.
- [DEMART98] C. DEMARTY & S. BEUCHER. « Color segmentation algorithm using an HSL transformation ». Dans *Mathematical Morphology and its Applications to Image and Signal Processing*, pages 231–238, 1998.
- [DIBOS97] F. DIBOS & G. KOEPLER. « Segmentation d’images couleur par méthode variationnelle ». Dans *16 ème colloque GRETSI*, pages 367–370, 1997.
- [DIZENZ86] S. DIZENZO. « A note on the gradient of a multi-image ». *Computer Vision, Graphics and Image Processing*, vol. 33, pages 116–126, 1986.
- [DOMBRE03] J. DOMBRE. « Systèmes de représentation multi-échelles pour l’indexation et la restauration d’archives médiévales couleur ». Thèse de doctorat, Université de Poitiers, Décembre 2003.
- [DONG05] J. DONG, A. KRZYK & C. SUEN. « Fast SVM training algorithm with decomposition on very large data sets ». *IEEE trans. on Pattern Analysis and Machine Intelligence*, vol. 27, pages 603–618, 2005.
- [DUDA01] R. DUDA, P.HART & D.STORK. « Pattern Classification ». Xiley Interscience - 2e édition, 2001.
- [DUIN00] R. DUIN & D. TAX. « Experiments with classifiers combining rules ». Dans *Multiple classifier systems*, vol. 1857, pages 16–29, 2000. Springer : Berlin.
- [EASTWO73] D. EASTWOOD. « A simple modification to improved the visual uniformity of the CIE 1964 U*V*W* color space ». Dans *Association Internationale de la Couleur, Colour73*, pages 293–296, 1973. New York.
- [FAUGER79] O. FAUGERAS. « Digital image processing within the framework of a human visual model ». *IEEE trans. on Acoustic, speech and signal processing*, 27(7), pages 380–393, 1979.
- [FISHER36] R. FISHER. « The use of multiple measurements in taxonomic problems ». *Anal of Eugenics*, vol. 7, pages 179–188, 1936.
- [FISHER58] W. FISHER. « On grouping for maximum homogeneity ». *JASA*, vol. 53, pages 789–798, 1958.
- [FONTAI04] M. FONTAINE. « Segmentation non supervisée d’images par analyse de la connexité des pixels ». Thèse de doctorat, Université des Sciences et des Techniques de Lille, 2004.
- [FRIGER01] J. FRIGERIO. « Perception humaine de la couleur ». Dans *Ecole de printemps : la couleur des matériaux*, Mars 2001. [Http://www.clubvisu.org/infovisu47/Frigerio-JPB.doc](http://www.clubvisu.org/infovisu47/Frigerio-JPB.doc).
- [FRIGUI96] H. FRIGUI & R. KRISHNAPURAM. « A robust algorithm for automatic extraction of an unknown number of clusters from noisy data ». *IEEE Tras on Pattern Recognition Letters*, 17(12), pages 1223–1232, 1996.

- [GALICH89] S. GALICHET. « Etude d'un système d'incrustation d'images vidéo couleur ». Thèse de doctorat, Université de Technologie de Compiègne, Décembre 1989.
- [GARBY79] C. GARBY. « Modélisation de la couleur dans le cadre de l'analyse d'images et de son application à la cytologie automatique ». Thèse de doctorat, Institut National Polytechnique de Grenoble, Décembre 1979.
- [GARRID98] L. GARRIDO, P. SALEMBIER & D. GARCIA. « Extensive operators in partition lattices or image sequence analysis ». *Signal Processing*, 6(2), pages 157–180, 1998.
- [GOMILA01] C. GOMILA. « Mise en correspondance de partitions en vue du suivi d'objets ». Thèse de doctorat, Centre de Morphologie Mathématique, Ecole des Mines de Paris, 2001.
- [GÉRAUD01] T. GÉRAUD, P. STRUB & J. DARBON. « Segmentation d'Images en Couleur par Classification Morphologique Non Supervisée ». Dans *International Conference on Image and Signal Processing*, vol. 1, pages 387–394, 2001.
- [GRECU00] H. GRECU & P. LAMBERT. « Simplification of Color Image Segmentation Using a Fuzzy Attributed Graph. ». Dans *ICIP*, pages 525–528, 2000.
- [GUIGUE01] L. GUIGUES, H. L. MEN & J. COCQUEREZ. « Segmentation d'images par minimisation d'un critère mdl dans une pyramide de segmentations ». Dans *Proceedings of GRETSI*, 2001.
- [GUIGUE03A] L. GUIGUES. « Modèles multi-échelles pour la segmentation d'images ». Thèse de doctorat, Université de Cergy-Pontoise, 2003.
- [GUIGUE03B] L. GUIGUES, H. L. MEN & J. COCQUEREZ. « The hierarchy of the cocoons of a graph and its application to image segmentation. ». *Pattern Recognition Letters*, 24(8), pages 1059–1066, 2003.
- [HANBUR01] A. HANBURY & J. SERRA. « Mathematical morphology in the HLS colour space ». Dans *Proc. of BMVC'2001*, vol. 2, pages 451–460, 2001.
- [HANBUR02] A. HANBURY & J. SERRA. « A 3D-polar coordinate colour representation suitable for image analysis ». Rapport technique N-37/02/MM, CMM-Ecole des Mines de Paris, Juin 2002.
- [HARIS98] K. HARIS, S. EFSTRATIADIS, N. MAGLAVERAS, A. AGGELOS & K. KATSAGGELOS. « Hybrid Image Segmentation Using Watersheds and Fast Region Merging ». *IEEE Trans on Image Processing*, 7(12), pages 1684–1699, 1998.
- [HOROWI74] S. HOROWITZ & S. PAVLIDIS. « Picture segmentation by a directed split and merge procedure ». Dans *Second International Conference on Pattern Recognition*, pages 424–433, 1974.
- [HOROWI76] S. HOROWITZ & T. PAVLIDIS. « Picture segmentation by a Tree traversal algorithm ». *J. Assoc. Comput. Math.*, 2(23), pages 368–388, 1976.
- [HÉRAUL94] J. HÉRAULT & C. JUTTEN. « Réseaux neuronaux et traitement du signal ». *Traité des nouvelles technologies (série traitement du signal)*, 1994. Ed. Hermès.

- [IWANOW99] M. IWANOWSKI & J. SERRA. « Morphological Interpolation and Color Images ». Dans *Proceedings of the 10th International Conference on Image Analysis and Processing*, pages 50–55, 1999.
- [JAIN00] A.-K. JAIN, R.-P.-W. DUIN & J. MAO. « Statistical pattern recognition : A review ». *IEEE transactions on PAMI*, 22(1), pages 4–37, 2000.
- [JOLION03] J. JOLION. « Stochastic pyramid revisited ». *Pattern Recognition Letters*, 24(8), pages 1035–1042, 2003.
- [KITTLE98] J. KITTLER, M. HATEF, R.-P. DUIN & J. MATAS. « On combining Classifiers ». *IEEE transactions on PAMI*, 20(3), pages 226–239, Mars 1998.
- [KOEPL94] G. KOEPFLER, C. LOPEZ & J. MOREL. « A multiscale algorithm for image segmentation by variational method ». *SIAM Journal on Numerical Analysis*, 31(1), pages 282–299, 1994.
- [KOPPEN99] M. KOPPEN, C. NOWACK & G. ROSEL. « Pareto-Morphology for Color Image Processing ». Dans *The 11th Scandinavian Conference on Image Analysis*, vol. 1, pages 195–202, 1999.
- [KOWALI90] P. KOWALISKI. « Vision et mesure de la couleur ». Paris : Masson, 2 édition, 1990.
- [KROPAT95] W. KROPATSCH. « Building irregular pyramids by dual graph contraction ». *IEE Vision, Image Signal Process*, 142(6), pages 366–374, 1995.
- [KROPAT99] W. KROPATSCH, A. LEONARDIS & H. BISCHOF. « Hierarchical Adaptive and Robust Methods for Image Understanding ». *Surveys on Mathematics for Industry*, vol. 9, pages 1–47, 1999.
- [KUNCHE00] L. KUNCHEVA, C. WHITAKER, C. SHIPP & R. DUIN. « Is independence good for combining classifiers ». Dans *ICPR*, vol. 2, pages 168–171, 2000.
- [KUNCHE01] L. KUNCHEVA, J. BEZDEK & R. DUIN. « Decision templates for multiple classifier fusion : an experimental comparison ». *Pattern Recognition*, 34(1), pages 299–314, 2001.
- [LALLIC03] S. LALLICH, F. MUHLENBACH & J. JOLLION. « A test to control a region growing process within a hierarchical graph ». *Pattern Recognition*, vol. 36, pages 2201–2211, 2003.
- [LAMBER99] P. LAMBERT & T. CARRON. « Symbolic fusion of luminance-hue-chroma features for region segmentation ». *Pattern Recognition*, 32(11), pages 1857–1872, 1999.
- [LAMBER00] P. LAMBERT & L. MACAIRE. « Filtering and segmentation : the specificity of color images ». Dans *Color in Graphics and Image Processing*, vol. 1, pages 57–71, 2000. Saint Etienne.
- [LAUREN03] H. LAURENT, S. CHABRIER, C. ROSENBERGER, B. EMILE & P. MARCHÉ. « Etude comparative de critères d'évaluation de la segmentation ». Dans *GRETSI*, pages 150–153, 2003.
- [LEBRUN05] G. LEBRUN, C. CHARRIER, O. LEZORAY, C. MEURIE & H. CARDOT. « A fast and efficient segmentation scheme for cell microscopic image ». Dans *World Congress of Cellular and Molecular Biology*, 2005. à paraître.

- [LEVINE85] M. LEVINE & A. NAZIF. « Dynamic measurement of computer generated image segmentations ». *IEEE Trans on PAMI*, 7(25), pages 155–164, 1985.
- [LEZORA00A] O. LEZORAY. « Segmentation d’images couleur par morphologie mathématique et classification de données par réseaux de neurones : application à la classification de cellules en cytologies des sereuses ». Thèse de doctorat, université de Caen basse-Normandie, Janvier 2000.
- [LEZORA00B] O. LEZORAY, A. ELMLOATAZ, H. CARDOT & M. REVENU. « Segmentation d’images couleur, applications en microscopie cellulaire ». *Traitement du Signal*, 17(1), pages 33–45, 2000.
- [LEZORA02A] O. LEZORAY & H. CARDOT. « Cooperation of color pixel classification schemes and color watershed : a study for microscopical images ». Dans *IEEE transactions on Image Processing*, vol. 11-7, pages 783–789, 2002.
- [LEZORA02B] O. LEZORAY & H. CARDOT. « Histogram and watershed based segmentation of color images ». Dans *Proceedings of CGIV’2002*, pages 358–362, 2002.
- [LEZORA03A] O. LEZORAY. « Supervised automatic histogram clustering and watershed segmentation. Application to microscopic medical images ». *Image Analysis and Stereology*, 22(2), pages 113–120, 2003.
- [LEZORA03B] O. LEZORAY. « Unsupervised 2D multiband histogram clustering and region merging for color image segmentation ». Dans *ISSPIT*, pages 267–270, 2003.
- [LEZORA03C] O. LEZORAY & H. CARDOT. « Segmentation of color images by clustering 2D histogram and merging regions ». *Moroccan Journal of Control Computer Science and Signal Processing*, 2003.
- [LEZORA04] O. LEZORAY & C. CHARRIER. « Segmentation d’images couleur par coalescence non supervisée d’histogrammes 2D et fusion de régions selon la théorie de Dempster-Shafer ». *Traitement du Signal*, 21(6), pages 605–621, 2004.
- [LEZORA05] O. LEZORAY, C. MEURIE, P. BELHOMME & A. ELMOATAZ. « Hiérarchie de partitions pour la simplification et la segmentation d’images couleur ». Dans *COmpression et REprésentation des Signaux Audiovisuels*, 2005.
- [LEZORA06] O. LEZORAY & C. CHARRIER. « Color calibration for microscopy imaging ». Dans *Proc. IST/SID Tenth Color Imaging Conference*, 2006.
- [LIANG87] L. LIANG. « Contribution à la segmentation chromatique des images. Application à l’identification d’objets colorés ». Thèse de doctorat, Institut National Polytechnique de Toulouse, Juillet 1987.
- [LIM90] Y. LIM & S.U.LEE. « On the color image segmentation algorithm based on the thresholding and the fuzzy c-means techniques ». *Pattern Recognition*, 23(9), pages 935–952, 1990.
- [LINDE80] Y. LINDE, A. BUZO & R. GRAY. « on algorithm for vector quantizer design ». *IEEE Trans on Communications*, pages 702–710, 1980.

- [LITTMAN97] E. LITTMAN & E. RITTER. « colour image segmentation : a comparison of neutral and statistical methods ». *IEEE Transaction on Neural Networks*, 8(1), pages 175–785, 1997.
- [LIU94] J. LIU & Y. YANG. « Multiresolution color image segmentation ». *IEEE Trans on PAMI*, 16(7), pages 689–700, 1994.
- [LOUVER02] G. LOUVERDIS, M. VARDAVOULIA, I. ANDREADIS & P. TSALIDES. « A new approach to morphological color image processing ». *Pattern recognition*, 35(8), pages 1733–1741, 2002.
- [LOZANO98] V. LOZANO. « Contribution de l’analyse d’images couleur au traitement des images textiles ». Thèse de doctorat, Université Jean Monnet de Saint Etienne, Janvier 1998.
- [MACAIR04] L. MACAIRE. « Exploitation de la couleur pour la segmentation et l’analyse d’images ». Thèse de doctorat, Université des Sciences et des Technologies de Lille, Novembre 2004. Habilitation à Diriger des Recherches.
- [MACQUE67] J. MACQUEEN. « Some methods for classification and analysis of multivariate observations ». Dans *Berkeley Symposium on Mathematical Statistics and Probability*, vol. 1, pages 281–297, 1967.
- [MAKROG01] S. MAKROGIANNIS, G. ECONOMOU & S. FOTOPOULOS. « A Graph Theory Approach for Automatic Segmentation of Color Images ». Dans *Int. Workshop on Very Low Bitrate Video Coding (VLBV 2001)*, pages 162–166, 2001.
- [MAKROG02] S. MAKROGIANNIS, G.ECONOMOU & S. FOTOPOULOS. « Region oriented compression of color images using fuzzy inference and fast merging ». *Pattern Recognition*, vol. 35, pages 1807–1820, 2002.
- [MARTIN02] D. MARTIN. « An empirical approach to grouping and segmentation ». Thèse de doctorat, University of California, Berkeley : USA, 2002.
- [MARTÍN04] A. MARTÍNEZ-USÓ, F. PLA & P. GARCÍA-SEVILLA. « A Novel Energy Minimization Criterion for Color Image Segmentation ». Dans *International Conference on Pattern Recognition*, vol. 3, pages 206–209, 2004.
- [MEAS-Y04] V. MEAS-YEDID, E. GLORY, E. MORELON, C. PINSET, G. STAMON & J. OLIVO-MARIN. « Automatic color space selection for biological image segmentation ». Dans *ICPR*, vol. 3, pages 514–517, 2004.
- [MEER89] P. MEER. « Stochastic image pyramids ». Dans *Computer Vision Graphics Image Processing*, vol. 45, pages 269–294, 1989.
- [MEURIE02] C. MEURIE, O. LEZORAY, H. CARDOT & A. ELMOATAZ. « Classification de pixels pour la segmentation d’images couleur : Application en cancérologie ». Dans *Forum Jeunes Chercheurs du GDR-ISIS*, 2002.
- [MEURIE03A] C. MEURIE, G. LEBRUN, O. LEZORAY & A. ELMOATAZ. « Comparison of supervised pixels-based color image segmentation methods. Application in cancerology ». *WSEAS Transactions on Computers*, 2(3), pages 739–744, 2003. ISSN 1109-2750.

- [MEURIE03B] C. MEURIE, G. LEBRUN, O. LEZORAY & A. ELMOATAZ. « A comparison of supervised pixels-based color image segmentation methods. Application in cancerology ». Dans *WSEAS International Conference On Signal, Speech and Image Processing*, 2003.
- [MEURIE03C] C. MEURIE, G. LEBRUN, O. LEZORAY & A. ELMOATAZ. « A supervised segmentation scheme for cancerology color images ». Dans *IEEE International Symposium on Signal Processing and Information Technology*, 2003.
- [MEURIE03D] C. MEURIE, O. LEZORAY, H. CARDOT & A. ELMOATAZ. « Comparaison de classifieurs non-supervisés pour la segmentation d'images couleur : Application en imagerie biomédicale ». Dans *IAPR International Conference on Image and Signal Processing*, vol. 1, pages 30–37, 2003.
- [MEURIE03E] C. MEURIE, O. LEZORAY & A. ELMOATAZ. « Segmentation d'images couleur par fusion de classification de pixels. Application en imagerie biomédicale ». Dans *16^{ème} journées de l'Association Française d'Informatique Graphique*, pages 104–110, 2003.
- [MEURIE04A] C. MEURIE, O. LEZORAY, C. CHARRIER & A. ELMOATAZ. « Combination of Multiple Pixel Classifiers for Microscopic Image Segmentation ». *International Journal of Robotics and Automation*, 20(2), pages 63–69, 2004.
- [MEURIE04B] C. MEURIE, O. LEZORAY & A. ELMOATAZ. « Multiple pixel classifier combination for bronchial tumors image segmentation ». Dans *International Conference on Complex Systems Intelligence and Modern technological Applications, Special Session*, vol. 1, pages 305–310, 2004.
- [MEURIE04C] C. MEURIE, O. LEZORAY, A. ELMOATAZ, M. LECLUSE & H. ELIE. « Segmentation d'images couleur par classification de pixels et morphologie mathématique ». Dans *27^{ème} journées de la section française de l'International Society for Stereology*, 2004.
- [MEYER90] F. MEYER & S. BEUCHER. « Morphological segmentation ». *Journal of Visual Communication and Image representation*, 1(1), pages 21–45, 1990.
- [MEYER92] F. MEYER. « Color Image Segmentation ». Dans *Proceedings of the International Conference on Image Processing and its Applications*, pages 303–306, 1992.
- [MEYER98] F. MEYER. « From connected operators to levellings ». *Mathematical Morphology and its Applications to Image and Signal Processing*, pages 191–199, 1998.
- [MICHIE94] D. MICHIE, D. SPIEGELHALTER & C. TAYLOR. « Machine learning, neural and statistical classification ». vol. 6, pages 84–106, 1994.
- [MOGHAD97] A. MOGHADDAMZADEH & N. BOURKABIS. « A fuzzy region growing approach for segmentation of color images ». *Pattern Recognition*, 30(6), pages 867–881, 1997.
- [MONGA87] O. MONGA. « an optimal region growing algorithm for image segmentation ». *IJPRAI*, 1(4), pages 351–375, 1987.

- [MORONE02] N. MORONEY, M. FAIRCHILD, R. HUNT, C. LI, M. LUO & T. NEWMAN. « The CIECAM02 Color Appearance Model. ». Dans *Proc. IST/SID Tenth Color Imaging Conference*, pages 23–27, 2002.
- [MUMFOR89] D. MUMFORD & J. SHAH. « Optimal approximation by piecewise smooth functions and associated variational problems ». Dans *Comm On Pure and Applied Math*, 17(4), pages 577–685, 1989.
- [NOCK01] R. NOCK. « Fast and reliable color region merging inspired by decision tree pruning ». Dans *IEEE International Conference on Computer Vision and Pattern Recognition*, pages 271–276, 2001.
- [NOCK04] R. NOCK & F. NIELSEN. « Statistical Region Merging ». *IEEE transactions on Pattern Analysis and machine Intelligence*, 26(11), pages 1452–1458, 2004.
- [OHLAND78] R. OHLANDER, K. PRICE & D. REDDY. « Picture segmentation using a recursive region splitting method ». *Computer Graphics and Image Processing*, vol. 8, pages 313–333, 1978.
- [OHTA80] Y. OHTA, T. KANADE & T. SAKAI. « Color information for region segmentation ». Dans *Computer Graphics and Image Processing*, vol. 13, pages 222–241, 1980.
- [ORCHAR91] M. ORCHARD & C. BOUMAN. « Color quantization of images ». *IEEE Transactions on Signal Processing*, 39(12), pages 2677–2690, 1991.
- [ORTIZ00] F. ORTIZ, F. TORRES, S. PUENTE, F. CANDELAS & P. GIL. « Use of the Hue/Saturation/Intensity Color Spaces to the Morphological ». Dans *Proceedings of the First International Conference on Color in Graphics and Image Processing*, pages 219–224, 2000.
- [ORTIZ01] F. ORTIZ, F. TORRES, J. ANGULO & S. PUENTE. « Comparative study of vectorial morphological operations in different color spaces ». Dans *Proc. of Intelligent Robots and Computer Vision XX : Algorithms, Techniques, and Active Vision*, vol. 4572, pages 259–268, 2001.
- [PANJWA95] D. PANJWANI & G. HEALEY. « Markov random field models for unsupervised segmentation of textured color images ». *IEEE Trans on Pattern Analysis and Machine intelligence*, 17(10), pages 939–954, 1995.
- [PAPAS92] T. PAPAS. « an adaptative clustering algorithm for image segmentation ». *IEEE Transactions on Signal Processing*, vol. 40, pages 901–914, 1992.
- [PARK98] S. PARK, I. YUN & S.U.LEE. « color image segmentation based on 3-d clustering : morphological approach ». *Pattern recognition*, 31(8), pages 1061–1076, 1998.
- [PAVLID77] T. PAVLIDIS. « Structural Pattern recognition ». Springer Verlag, 1977.
- [PERONA90] P. PERONA & J. MALIK. « Scale-space and edge detection using anisotropic diffusion ». *IEEE transactions on Pattern Analysis and Machine Intelligence*, 12(7), pages 629–639, 1990.
- [PETERS97] R. A. PETERS. « Mathematical morphology for angle valued images ». Dans *SPIE International Conference on Electronic Imaging*, 1997.
- [PETROU98] M. PETROU, L. SHAFARENKO & J. KITTLER. « Histogram-based segmentation in a perceptually uniform color space ». *IEEE Trans on Image Processing*, vol. 7, pages 1354–1358, 1998.

- [PETROV03] A. PETROVIC & P. VANDERGHEYNST. « Multiscale Variational Approach to Simultaneous Image Regularization and Segmentation ». Dans *ISPA*, 2003.
- [PHILIP00] S. PHILIPP-FOLIGUET. « Segmentation d'images en régions floues ». Dans *Rencontres Francophones sur la Logique Floue et ses Applications*, pages 189–196, 2000.
- [PHILIP01] S. PHILIPP-FOLIGUET. « Evaluation des méthodes de segmentation d'images couleur ». Dans *Ecole de printemps du GDR-ISIS opération Imagerie Couleur*, Avril 2001. Pau.
- [PITAS91] I. PITAS & P. TSALIDES. « Multivariate Ordering in Color Image Filtering ». *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 1, pages 247–259, 1991.
- [PLATT98] J. PLATT. « Sequential minimal optimization : A fast algorithm for training support vector machines ». Dans *Advances in Kernel Methods - Support Vector Learning*, pages 185–208, 1998.
- [PRATT78] W. PRATT. « Digital image processing ». New York : John Wiley and Sons, 1978.
- [PUZICH00] J. PUZICHA, M. HELD, J. KETTERER & J. BUHMANN. « On spatial quantization of color images ». *IEEE Trans on Image Processing*, vol. 9, pages 666–682, 2000.
- [RAFFY99] G. RAFFY. « Vision numérique couleur appliquée à l'évaluation de la qualité de carcasses de dindes ». Thèse de doctorat, Université Blaise pascal de Clermont-Ferrand, Mars 1999.
- [RISSON01] V. RISSON. « Application de la morphologie mathématique à l'analyse des conditions d'éclairage des images couleur ». Thèse de doctorat, Centre de Morphologie Mathématique, École des Mines de Paris, 2001.
- [ROBINS98] G. ROBINSON. « Segmentation via RGB clustering », 1998. [Http ://www.npac.syr.edu/copywrite/pcw/node431.html/](http://www.npac.syr.edu/copywrite/pcw/node431.html/).
- [ROLI02] F. ROLI & G. GIACINTO. « Design of multiple Classifier systems ». Hybrid methods in pattern recognition. World Scientific Publishing, 2002. H. Bunke and A. Kandel.
- [RUMELH86] D. RUMELHART, G. HILTON & R. WILLIAMS. « Learning internal representations by error propagation », vol. 1. MIT Press, 1986.
- [RUTA00] D. RUTA & B. GABRYS. « An Overview of Classifier Fusion Methods ». *Computing and Information Systems*, vol. 7, pages 1–10, 2000.
- [SAARIN94] K. SAARINEN. « color image segmentation by a watershed algorithm and region adjacency graph processing ». Dans *International Conference on Image Processing*, vol. 3, pages 1021–1025, 1994.
- [SALEMB92] P. SALEMBIER & J. SERRA. « Morphological Multiscale image segmentation ». Dans *SPIE Visual Communications and Image Processing*, pages 620–631, 1992.
- [SALEMB95] P. SALEMBIER & J. SERRA. « Flat Zones Filtering, Connected Operators, and Filters by Reconstruction ». *IEEE Trans on Image Processing*, 4(8), pages 1153–1160, 1995.

- [SALEMB97] P. SALEMBIER, L. GARRIDO & D. GARCIA. « Image sequence analysis and Merging algorithm ». Dans *International Workshop on Very Low Bit-rate Video, VLBV'97*, pages 1–8, 1997.
- [SALEMB00] P. SALEMBIER & L. GARRIDO. « Binary partition tree as an efficient representation for image processing, segmentation and information retrieval ». *IEEE transactions on Image Processing*, 9(4), pages 561–576, 2000.
- [SAMET80] H. SAMET. « Region representation : quadtrees from binary arrays ». Dans *Computer Graphics and Image Processing*, vol. 13, pages 88–93, 1980.
- [SAMMOU97] R. SAMMOUDA, N. NIKI & H. NISHITANI. « hopfiels neural-network for the multichannel segmentation of magnetic-resonance cerebral images ». *Pattern Recognition*, 30(6), pages 921–927, 1997.
- [SAVOJI85] M. SAVOJI & R. BURGE. « Note on differents methods based on the Karhunen-Loeve expansion and used in image analysis ». *Computer Vision, Graphics and Image Processing*, vol. 29, pages 259–269, 1985.
- [SCHETT93] R. SCHETTINI. « A segmentation algorithm for color images ». *Pattern Recognition Letters*, 14(12), pages 499–506, 1993.
- [SCHUPP01] S. SCHUPP, A. ELMOATAZ, P. HERLIN & D. BLOYET. « Mathematical morphologic segmentation dedicated to quantitative immunohistochemistry ». *Analytical and Quantitative Cytology and Histology*, vol. 23, 2001.
- [SERRA88] J. SERRA. « Image Analysis and Mathematical Morphology : Theoretical Advances », vol. 2. Academic Press, London, 1988.
- [SERRA00] J. SERRA. « Connectivity for sets and functions ». *Fundamenta Informaticae*, vol. 41, pages 147–186, 2000.
- [SERRA03] J. SERRA. « Connexions et segmentations d'images ». *Traitement du signal*, 20(3), 2003.
- [SHAFAR97] L. SHAFARENKO, M. PETROU & J. KITTLER. « Automatic Watershed Segmentation of Randomly Textured Color Images ». *IEEE transactions on Image Processing*, 6(11), pages 1530–1543, 1997.
- [SOILLE96] P. SOILLE. « morphological partitioning of multispectral images ». *Journal of Electronic Imaging*, 18(4), pages 252–265, 1996.
- [SORIA-02] A. SORIA-FRISCH & M. KOPPEN. « The Fuzzy Integral as Similarity Measure for a New Color Morphology ». Dans *The First European Conference on Color in Graphics, Imaging and Vision*, pages 523–526, 2002.
- [SÈVE96] R. SÈVE. « Physique de la couleur. De l'apparence colorée à la technique colorimétrique ». Paris : Masson, 1996.
- [TA04] V. TA. « Représentation d'images par arbres binaires de régions », 2004. Université de Caen Basse-Normandie, Rapport de DEA.
- [TALBOT98] H. TALBOT, C. EVANS & R. JONES. « Complete Ordering and Multivariate Mathematical ». Dans *Proceedings of the fourth international symposium on Mathematical morphology and its applications to image and signal processing*, pages 27–34, 1998.

- [THEOHA05] C. THEOHARATOS, G. ECONOMOU & S. FOTOPOULOS. « Color edge detection using the minimal spanning tree ». *Pattern recognition*, vol. 38, pages 603–606, 2005.
- [TOMINA92] S. TOMINAGA. « Color classification of natural color images ». *Color Research and Application*, 17(4), pages 230–239, 1992.
- [TRÉMEA93] A. TRÉMEAU. « Contribution des modèles de la perception visuelle à l'analyse d'image couleur ». Thèse de doctorat, Université Jean Monnet de Saint Etienne, Octobre 1993.
- [TRÉMEA95] A. TRÉMEAU, V. LOZANO & B. LAGET. « How to optimize the use of the LHC color space in color image processes ». Dans *ICS*, 14(2), pages 223–228, 1995.
- [TRÉMEA97] A. TRÉMEAU & N. BOREL. « A region growing and merging algorithm to color segmentation ». *Pattern Recognition*, 30(7), pages 1191–1203, 1997.
- [TRÉMEA00] A. TRÉMEAU & P. COLANTONI. « Regions adjacency graph applied to color image segmentation ». *IEEE Transactions on Image Processing*, 9(4), pages 735–744, 2000.
- [TRÉMEA04] A. TRÉMEAU, C. FERNANDEZ-MALOIGNE & P. BOTTON. « Image numérique couleur : de l'acquisition au traitement ». Paris : Dunod, 2004.
- [TSCHUM01] D. TSCHUMPERLÉ & R. DERICHE. « Constrained and Unconstrained PDE's for vector image restoration ». Dans *SCIA*, pages 153–160, 2001.
- [T.YOUN02] T. YOUNG. « On the theory of light and colors ». *Philosophical Transactions of the Royal Society*, page 91, 1802.
- [ULTRÉ96] V. ULTRÉ. « Contribution à la segmentation chromatique d'images de mosaïque en couleur ». Thèse de doctorat, Université des Sciences et des Technologies de Lille, Janvier 1996.
- [VANDEN00] N. VANDENBROUCKE. « Segmentation d'images couleur par classification de pixels dans des espaces d'attributs colorimétriques adaptés. Application à l'analyse d'image de football ». Thèse de doctorat, Université de Lille 1, décembre 2000.
- [VANHAM00] I. VANHAMEL, I. PRATIKAKIS & H. SAHLI. « Automatic Watershed Segmentation of Color Images ». Dans *International Symposium on Mathematical Morphology and its Applications to Image and Signal Processing V*, pages 207–214, 2000.
- [VANHAM03] I. VANHAMEL, I. PRATIKAKIS & H. SAHLI. « Multiscale Gradient Watersheds of Color Images ». *IEEE transactions on Image Processing*, 12(6), pages 617–626, 2003.
- [VAPNIK71] V. VAPNIK & A. CHERVONENKIS. « On the uniform convergence of relative frequencies of events to their probability ». Dans *Theory of Probability and its Applications*, vol. 16, pages 264–280, 1971.
- [VAPNIK98] V. VAPNIK. « Statistical Learning Theory ». 1998.
- [VARDAV01] M. VARDAVOULIA, I. ANDREADIS & P. TSALIDES. « A new vector median filter for colour image processing ». *Pattern Recognition Letters*, 22(6), pages 1733–1741, 2001.

- [VINCEN91] L. VINCENT & P. SOILLE. « Watersheds in Digital Spaces : An efficient Algorithm Based on Immersions Simulations ». *IEEE transactions on PAMI*, 13(16), pages 583–598, 1991.
- [XU98] L. XU, A. KRZYZAK & C.-Y. SUEN. « Methods for combinig multiple classifiers and their applications to handwriting recognition ». *IEEE transactions on Systems Man and Cybernetics*, 22(3), pages 418–435, 1998.
- [XUE03] H. XUE, T. GÉRAUD & A. DURET-LUTZ. « Multibandes segmentation using morphological clustering and fusion application to color image segmentation ». Dans *ICIP*, vol. 1, pages 353–356, 2003.
- [ZANOQU01] F. ZANOQUERA. « Segmentation interactive d’images fixes et de séquence vidéo basées sur des hiérarchies de partitions ». Thèse de doctorat, Centre de Morphologie Mathématique, Ecole des Mines de Paris, 2001.
- [ZHANG96] Y. ZHANG. « A survey on evaluation methods for image segmentation ». *Pattern Recognition*, 29(8), pages 1335–1346, 1996.
- [ZHU96] S. ZHU & A. YUILLE. « Region competition : Unifying snakes, region growing, and bayes/mdl for multiband image segmentation ». *IEEE Trans. on Pattern Analysis and machine Intelligence*, 18(9), pages 884–900, 1996.
- [ZOUARI02] H. ZOUARI, L. HEUTTE, Y. LECOURTIER & A. ALIMI. « Un panorama des méthodes de combinaison de classifieurs en reconnaissance des formes ». Dans *RFIA*, vol. 2, pages 499–508, 2002. Angers, France.
- [ZUGAJ98] D. ZUGAJ & V. LATTUATI. « a new approach of color images segmentation based on fusing region and edge segmentation outputs ». *Pattern Recognition*, 31(2), pages 105–113, 1998.

PERCEPTION HUMAINE DE LA COULEUR

NOUS allons présenter ici les éléments essentiels intervenant dans le processus de perception de la couleur chez l'être humain c'est-à-dire la source lumineuse, le matériau, l'oeil et le cerveau.

Depuis très longtemps, l'homme tente de comprendre les phénomènes complexes liés à la couleur. Jusqu'au XVI siècle, la lumière était considérée comme composée de grains de nature différente selon la couleur. Mais au XVII siècle, I. NEWTON montre qu'il est possible de décomposer la lumière blanche en un spectre de rayons lumineux à l'aide d'un prisme de verre et c'est alors que le concept de la couleur a pris forme. Puis au début du XIX siècle, T. YOUNG [T.YOUN02] établit la théorie trichromatique de la lumière qui fut par la suite améliorée par H.V. HELMOLTZ, et qui stipule que la rétine humaine possède trois types de cônes photorécepteurs couleur sensibles au rouge, au vert et au bleu. C'est alors que l'on vient à se demander comment l'être humain perçoit la lumière. Comme le montre J.M. FRIGERIO [FRIGER01], nous distinguerons trois phases pour décrire la perception humaine de la couleur (figure A.1) :

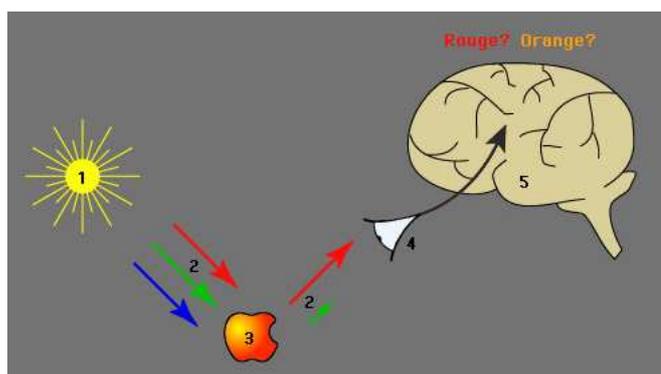


FIG. A.1 – La perception humaine de la couleur.

1. une phase physique produisant un stimulus de couleur. Celui-ci peut soit être créé directement à partir d'une source lumineuse soit parvenir de la réflexion et/ou de la diffusion d'une telle source sur un matériau ;
2. une phase physiologique transformant le stimulus reçu en un signal couleur transmis au système d'interprétation (le cerveau). Cela commence par le traitement optique effectué par le récepteur (l'oeil) pour créer une image sur la rétine. Cela se poursuit

par l'absorption des photons par les cônes et les bâtonnets et se termine par un pré-traitement permettant de réduire l'information destinée au système d'interprétation ;

3. une phase psychologique permettant l'identification de cette information suivie de son interprétation sous forme de couleur.

Les quatre éléments essentiels intervenant dans le processus de la perception humaine de la couleur à savoir : la source lumineuse, le matériau, le récepteur (l'oeil), le système d'interprétation (le cerveau) sont détaillés ci-après.

A.1 La source lumineuse

L'ensemble des longueurs d'onde composant un rayonnement est appelé spectre. L'oeil humain ne permet pas de discerner les différentes composantes d'un rayonnement et de ce fait ne perçoit que la résultante de ce dernier, fonction des différentes longueur d'ondes qui le composent et de leur intensité lumineuse respective. La vision humaine ne permet pas de voir la totalité du spectre mais uniquement des rayonnements dont la longueur d'onde est comprise entre 380 et 780 nm correspondant au spectre visible comme le montre la figure A.2.

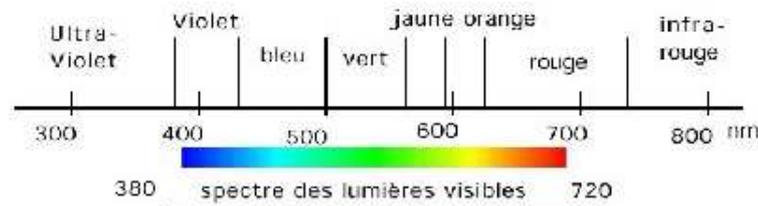


FIG. A.2 – Spectre des couleurs.

Comme le rappelle VANDENBROUCKE [VANDEN00], les sources lumineuses peuvent être définies en quatre grandes familles selon le type de spectre qu'elles émettent, c'est-à-dire en fonction de la répartition de l'énergie lumineuse émise dans les différentes longueurs d'onde :

1. le spectre continu pour lequel l'énergie de la lumière est émise de manière continue dans le domaine des longueurs d'ondes considéré. Ce sont les sources correspondant à l'émission lumineuse d'un solide chauffé comme par exemple les ampoules à incandescence, des bougies ou encore le soleil. La loi de Planck montre que le rayonnement de tous les corps chauffés répond à une même loi et que la répartition de l'énergie lumineuse en fonction de la longueur d'onde ne dépend que de la température. Pour anecdote, la lumière naturelle par temps couvert a une température de 6500K et correspond à la température de l'illuminant standard de la Commission Internationale de l'Éclairage (CIE) ;
2. le spectre discontinu présente des longueurs d'ondes pour lesquelles aucune énergie lumineuse n'est émise. Ce spectre discontinu correspond à des lampes à décharge électrique dans un gaz ionisé ;

3. le spectre mixte combine les deux spectres précédemment cités (continu et discontinu) et correspond au genre de spectre émis par des néons ou des tubes fluorescents ;
4. le spectre de raies présente quelques rares longueurs d'onde particulière (exemple : les lasers ou les diodes lasers).

A.2 Le matériau

La source lumineuse telle que nous venons de la décrire est dite *source primaire* puisqu'elle produit directement un rayonnement à partir d'une transformation d'énergie. Mais il existe un autre type de source lumineuse dite *secondaire* consistant à émettre un rayonnement électromagnétique issu de la réflexion ou de la transmission des rayonnements d'une source primaire par un matériau, ou encore issu de la combinaison de rayonnements de plusieurs sources. Ainsi lorsque nous regardons un objet (n'étant pas une source primaire), nous le distinguons parce qu'il est éclairé et le rayonnement lumineux après l'avoir frappé revient jusqu'à notre oeil. La couleur d'un matériau dépend de ces caractéristiques mais aussi de la façon dont il est éclairé et observé. Il convient donc d'avoir recours à une normalisation de l'éclairage et à des géométries d'analyse afin de s'éloigner de tous problèmes de reproductibilité. La Commission Internationale de l'Éclairage (CIE) a donc défini huit types de géométrie d'analyse répartis de façons égales pour les matériaux réfléchissant ou transmettant la lumière. Elle a également instauré différents illuminants correspondant à différents éclairages que nous détaillerons un peu plus loin dans ce chapitre.

A.3 Le récepteur humain : l'oeil

La fonction système optique de l'oeil est de focaliser un stimulus de couleur sur sa partie photosensible : la rétine. Cette fonction est rendue possible par les principaux éléments présentés sur la figure A.3 et décrits ci-dessous :

- la cornée : une membrane transparente et résistante située sur la face avant de l'oeil. Elle peut être assimilée à une lentille fixe d'une puissance d'environ 40 dioptries ;
- le cristallin : une lentille biconvexe dont la puissance varie en fonction de l'accommodation de 20 à 28 dioptries environ et nous permettant d'avoir une vision nette de ce que nous observons ;
- l'iris, se situant entre la cornée et le cristallin, est une membrane colorée jouant le rôle d'un diaphragme contrôlant ainsi le flux lumineux pénétrant dans l'oeil par augmentation ou diminution de la pupille ;
- l'humeur vitrée qui maintient la pression intra-oculaire est un liquide biologique transparent qui intervient dans le système optique par son indice de réfraction égal à 1,337 ;
- la fovéa correspond à une petite région circulaire de 1,5 cm de diamètre qui est le siège de l'acuité visuelle de l'être humain et essentiellement constituée de cônes.

Mais la rétine reste l'élément essentiel de la vision car cette fine membrane qui tapisse le fond de l'oeil et sur laquelle viennent se projeter les différentes images de la scène que

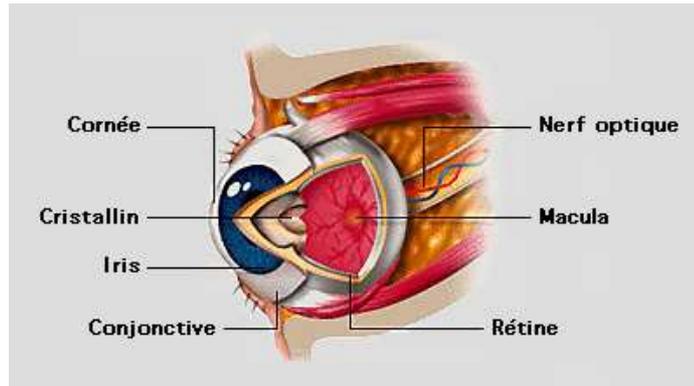


FIG. A.3 – L’œil humain.

nous observons contient à la fois les cellules sensibles à la lumière, les cellules responsables du pré-traitement spatial et colorimétrique de l’information et les cellules transmettant cette information au cerveau. La rétine contient deux types de cellules photo-sensibles à savoir les cônes et les bâtonnets qui selon KOWALISKI [KOWALI90] se trouvent respectivement au nombre de 4 à 7 millions et 110 à 125 millions. Les cônes permettent la vision diurne (vision photopique) et sont donc responsables de notre aptitude à distinguer les couleurs. Il existe trois types de cônes qui diffèrent par leurs sensibilités spectrales aux longueurs d’ondes et par conséquent au rouge, au vert et au bleu. Les bâtonnets ont une sensibilité plus grande que celle des cônes mais n’ont qu’un seul type de sensibilité spectrale. Ceci a pour conséquence de n’apporter aucune information colorimétrique mais uniquement photométrique et de permettre ainsi la vision nocturne (vision photopique). De part leur répartition hors de la fovéa, les bâtonnets sont utilisés pour la détection du mouvement et la vision périphérique.

La sensibilité des photorécepteurs à l’énergie photonique est due à la présence de pigments. Le pigment des bâtonnets est la rhodopsine permettant de percevoir la luminosité et le mouvement, celui des cônes est l’iodopsine permettant de différencier les couleurs. Pour ce faire, il existe trois types d’iodopsines définissant trois types de cônes selon la proportion de pigment de chaque type : les cônes S (Short) ou cyanolabes sensibles à des longueurs d’onde courtes (sensible au bleu), les cônes M (Médium) ou chlorolabes sensibles à des longueurs d’onde moyennes (sensible au vert) et les cônes L (Large) ou erythrolabes sensibles à des longueurs d’onde longues (sensible au rouge).

A.4 Le système d’interprétation : le cerveau

A l’entrée du nerf optique, notre œil a donc converti un stimulus de couleur en un signal couleur. Puis le nerf optique véhicule ce signal par différents intermédiaires jusqu’à notre cerveau. Le signal couleur serait codé sous la forme du modèle des couleurs opposées que nous décrivons par la suite puis transmis dans une partie du cerveau appelé cortex effectuant l’interprétation des couleurs. La notion d’interprétation employée ici a tout son sens puisqu’il s’agit vraiment de donner une explication sur le choix d’une couleur par rapport à une autre. Cette interprétation dépend de nombreux paramètres et il se peut

qu'elle soit différente d'un individu à un autre : elle dépend notamment de l'apprentissage que nous avons reçu des couleurs que nous percevons (par exemple une couleur rouge peut correspondre à une couleur pourpre pour un autre individu), mais elle est aussi liée à la condition d'éclairage (nous pouvons identifier la couleur d'un objet quelles que soient les conditions d'éclairage qu'il subit). Devant la variété des interprétations possibles, il semble mieux adapté de caractériser une couleur par trois grandeurs comme par exemple, la teinte, la saturation et la luminosité que nous expliquons ci-après :

1. la luminosité ou *brightness* en anglais est l'attribut d'une sensation visuelle selon laquelle une surface paraît émettre plus ou moins de lumière. Elle caractérise le niveau lumineux d'un stimulus de couleur et est traduite par des adjectifs comme clair, foncé, sombre, etc. La littérature [KOWALI90, SÈVE96] abonde de termes pour désigner la luminosité telle que l'intensité (*intensity* en anglais), l'éclairement (*illumination* en anglais), la clarté (*lightness* en anglais) ou encore la luminance ;
2. la teinte ou *hue* en anglais correspond à la longueur d'onde dominante d'un stimulus de couleur et donc aux dénominations de couleur comme le violet, le mauve, le rouge, etc. Mais rappelons que le blanc, le gris et le noir sont des couleurs achromatiques et donc n'ont pas de teintes ;
3. La saturation est une grandeur permettant d'estimer le niveau de coloration d'une teinte mais indépendamment de la luminosité contrairement au *chroma* qui lui correspond au degré de mélange de la longueur d'onde prédominante avec le blanc. Elle est traduite par des adjectifs comme vive, pâle, terne, etc.

