



République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



Mémoire de Magister

Présenté à

École Nationale Supérieure Polytechnique d'Alger

Laboratoire Signal & Communications

Équipe : Traitement d'Images & Reconnaissance de Formes

Pour obtenir le grade de :

Magister en Électronique

Par :

Nadia M'HAMDA BOULOUDANI

Ingénieur d'État en Électronique
DEA en Automatique Industrielle
email: nadia.mhamda@enp.edu.dz

Titre du mémoire :

Utilisation des Critères de Performance pour la Segmentation Automatique des Images Cytologiques Couleur

Soutenu le : 21 janvier 2009

Devant le jury composé de :

Président :	M. Hicham BOUSBIA SALAH	Maître de conférences, ENSP
Rapporteur :	Mme. Latifa HAMAMI	Professeur, ENSP
Examineurs :	Melle. Aïcha MOUSSAOUI	Chargée de cours, ENSP
	M. Mohamed Salah AÏT CHEIKH	Maître de conférences, ENSP
	M. Llies SAADAOU	Chargé de cours, ENSP

ملخص :

تحتل تجزئة الصورة مكانة مهمة جدا في معالجة الصور لأنها تساهم بدور كبير ومباشر في التشخيص والقرار، لا سيما في الميدان الطبي. إننا نقترح في هذا العمل تقسيما آليا للصور الخلوية الملونة والذي يهدف إلى فصل النواة والسيتوبلازم عن الخلفية للصورة الخلوية. يعمل هذا النظام الآلي على توفير أفضل تجزئة ممكنة للصورة المعنية، وذلك بالاعتماد على معايير تقييم التجزئة. في هذا المنهاج، وضعنا نظامين آليين: الأول يعمل في حلقة مفتوحة حيث يقوم باختيار أفضل تجزئة من بين عدة تجزئات مطبقة لقيم مختلفة لمعالم العمل. النظام الثاني يعمل في حلقة مغلقة وهو يشمل على مراقب ضبابي. هذا الأخير يقوم بتصحيح التجزئة في الوقت الحقيقي وذلك بتغيير قيم معالم العمل وفقا لمعايير تقييم التجزئة.

كلمات مفتاحية: التجزئة، معايير التقييم، معايير الأداء، معالم العمل، التجزئة الآلية، المراقب الضبابي، الصورة الخلوية الملونة.

Résumé :

La segmentation de l'image est une opération très importante dans la chaîne de traitement d'images puisqu'elle contribue directement dans le diagnostic et la prise de décision, notamment dans le domaine médical. Dans ce travail nous proposons une approche de segmentation automatique des images cytologiques couleur qui vise à séparer le noyau et le cytoplasme du fond de l'image cytologique. Le but de cette approche serait de fournir la meilleure segmentation en se basant sur les critères d'évaluation de cette dernière. Pour cela, nous avons conçu deux systèmes automatiques. Le premier travaille en boucle ouverte et choisit la meilleure segmentation parmi plusieurs effectuées pour différentes valeurs des paramètres d'action. Le deuxième système en boucle fermée comporte un contrôleur flou qui corrige la segmentation en temps réel en agissant sur les paramètres d'action selon l'indication des critères d'évaluation de la segmentation.

Mots clés : segmentation, critères d'évaluation, critères de performance, paramètres d'action, segmentation automatique, contrôleur flou, image cytologique couleur.

Abstract:

The image segmentation is a very important task in image processing because it contributes directly in the diagnosis and decision particularly in the medical field. In this work we propose an automatic segmentation approach of colored cytological images. It aims to separate the nucleus and cytoplasm from the background of the cytological image. This approach aims to provide the best segmentation based on its evaluating criteria. We have developed two automatic systems. The first one works in open loop and chooses the best segmentation among several ones made for different values of the action parameters. The second system, in feedback loop includes a fuzzy controller which corrects the segmentation in real time and changes the action parameters' values according to the indication of the evaluating segmentation criteria.

Key words: segmentation, evaluating criteria, performance criteria, action parameter, automatic segmentation, fuzzy controller, colored cytological image.

Remerciements

J'adresse mes grands remerciements à madame Latifa Hamami pour avoir accepté de diriger mon mémoire de magister, et pour m'avoir accueilli et intégré dans l'équipe de recherche du Traitement d'Images et Reconnaissance de Formes du Laboratoire Signal et Communications.

Mes remerciements vont à Mademoiselle Aïcha Moussaoui, Monsieur Llies Saadaoui et Monsieur Mohamed Salah Aït cheikh pour avoir accepté d'être examinateurs de ce mémoire. Je remercie également Monsieur Hicham Bousbia-Salah pour avoir bien voulu accepté de présider le jury de ce mémoire de magister.

Je tiens à remercier Mme Madaoui (sage femme) et Mme Agal (médecin), spécialistes en screening de frottis utérins au laboratoire de cytologie du service obstétrique de l'hôpital Hassen Badi, pour m'avoir fourni les lames d'échantillons de frottis cervicaux utilisées dans l'acquisition des images.

Un merci s'adresse à toutes les personnes qui m'ont apporté leur soutien de près ou de loin le long de mon travail de magister.

Je dédie ce travail,

*à mes parents,
à toute ma famille,
à mes amis et collègues
et à moi-même.*

Table des matières

Résumé	3
Table des figures	13
Introduction	15
1 Généralités	17
1.1 Introduction.....	17
1.2 Acquisition de l'image.....	17
1.2.1 Qu'est-ce qu'une image.....	17
1.2.2 Comment acquérir une image.....	18
1.2.3 Principe des dispositifs d'acquisition d'images couleur.....	20
1.3 La segmentation d'image.....	22
1.4 La théorie de la logique floue.....	23
1.4.1 Définition et petit historique.....	23
1.4.2 Les sous-ensembles flous.....	23
1.4.3 Opérateurs de base sur les sous-ensembles flous.....	24
1.4.4 La commande floue.....	25
1.4.5 La fuzzification.....	25
1.4.6 L'inférence floue.....	26
1.4.7 La défuzzification.....	27
1.5 Récapitulatif.....	28
2 Évaluation de la Segmentation	29
2.1 Introduction.....	29
2.2 Évaluation de la segmentation en régions.....	30
2.2.1 Critères supervisés.....	31
2.2.1.1 Critère de Yasnoff.....	31
2.2.1.2 Critère de Vinet.....	32
2.2.1.3 Critère de Martin.....	33
2.2.1.4 Critère de Hamming.....	33
2.2.1.5 Critère de Kara-Fallah.....	34
2.2.2 Critères non supervisés.....	34
2.2.2.1 Critère de Rosenfeld.....	34
2.2.2.2 Uniformité de Levine et Nazif.....	34
2.2.2.3 Uniformité de Sahoo.....	35
2.2.2.4 Uniformité de Cochran.....	35
2.2.2.5 Contraste de Levine et Nazif.....	36
2.2.2.6 Contraste de Zeboudj.....	36
2.2.2.7 Critère de Rosenberger.....	37
2.2.2.8 Critère de Liu.....	40
2.2.2.9 Critère de Borsotti.....	40

2.3	Évaluation de la segmentation en contours.....	41
2.3.1	Critères supervisés.....	41
2.3.1.1	Erreur de sur détection.....	41
2.3.1.2	Erreur de sous détection.....	41
2.3.1.3	Erreur de localisation.....	41
2.3.1.4	Erreur quadratique moyenne.....	42
2.3.1.5	Distance L_q	42
2.3.1.6	Distance de Küllback.....	42
2.3.1.7	Distance de Bhattacharya.....	42
2.3.1.8	Distance de Jensen.....	42
2.3.1.9	Mesure de Fram et deutsch.....	43
2.3.1.10	Distance de Hausdorff.....	43
2.3.1.11	Distance de Huttenlocher.....	44
2.3.1.12	Distance de Baddeley.....	44
2.3.1.13	Critère de Pratt.....	45
2.3.1.14	Mesure de Straster.....	45
2.3.1.15	Mesure de Peli et Malah.....	45
2.3.1.16	Critère d’Odet.....	45
2.3.1.17	Critère de Correia.....	46
2.3.1.18	Critère de Nguyen et Ziou.....	47
2.3.1.19	Critère de Lopez.....	47
2.3.2	Critères non supervisés.....	48
2.3.2.1	Critères de Levine et Nazif.....	48
2.3.2.2	Critère de Han et Kim.....	49
2.3.2.3	Critère de Kitchen et Rosenfeld.....	49
2.3.2.4	Critère de Gelfand.....	50
2.3.2.5	L’énergie d’une courbe.....	50
2.4	Évaluation dédiée ‘régions – contours’	51
2.4.1	Critère du champ de markov.....	51
2.4.2	Critère de Zhang.....	51
2.5	Conclusion.....	52
3	Implémentation de la Segmentation Automatique	53
3.1	Introduction.....	53
3.2	Étude de cas.....	53
3.3	Étapes de la procédure de la segmentation.....	54
3.3.1	Classification par l’algorithme du Fuzzy- C -Means (FCM).....	56
3.3.2	Étiquetage.....	58
3.3.3	Segmentation en contours.....	60
3.4	L’évaluation de la segmentation appliquée.....	61
3.4.1	Évaluation du résultat de la segmentation en régions.....	62
3.4.1.1	Critères supervisés.....	62
3.4.1.2	Critères non supervisés.....	63
3.4.2	Évaluation du résultat de la segmentation en contours.....	65
3.4.2.1	Critères supervisés.....	65
3.5	Correction et automatisation de la segmentation.....	66
3.5.1	Première approche.....	66
3.5.2	Deuxième approche.....	74
3.6	Conclusion	79
4	Applications et Résultats	81
4.1	Introduction.....	81
4.2	Première application : images cytologiques couleur.....	81
4.2.1	Acquisition des images cytologiques.....	81

4.2.2	Première approche.....	82
4.2.3	Deuxième approche.....	85
4.3	Deuxième application : autres types d'images.....	88
4.3.1	Première approche.....	88
4.3.2	Deuxième approche.....	90
4.4	Conclusion et commentaires.....	91
Conclusion et Perspectives		93
Bibliographie		95

Table des figures

1.1	Les différentes étapes du traitement d'image.....	17
1.2	Numérisation d'une image couleur.....	18
1.3	Exemples d'outils d'acquisition d'images.....	19
1.4	Représentation d'une image couleur dans un espace couleur (cas de l'espace <i>RVB</i>).....	20
1.5	Illustration du principe des caméras <i>CCD</i>	21
1.6	Fonction d'appartenance : (a) logique floue, (b) logique classique.....	24
1.7	Illustration des opérateurs de base.....	24
1.8	Schéma général d'une commande floue.....	25
1.9	Exemple de fuzzification.....	25
1.10	Représentation de l'implication de l'exemple donné.....	26
1.11	Mécanisme d'inférence floue pour des valeurs de deux entrées.....	27
1.12	Illustration des techniques basiques de la défuzzification.....	28
2.1	Différentes configurations ayant le même nombre de pixels mal classés et à la même distance mais d'impacts différents.....	32
2.2	Principe du critère de Vinet.....	33
3.1	Exemple du résultat de la classification par <i>FCM</i>	54
3.2	Fusion des classes selon le processus d'agglomération de Lambert-Grecu.....	54
3.3	Fusion des classes selon l'attribut couleur.....	55
3.4	Étiquetage de l'image classifiée.....	55
3.5	Suppression des petites régions et des effets de bord dans l'image segmentée.....	55
3.6	Détection de contours.....	56
3.7	Étapes de la procédure de la segmentation utilisée.....	56
3.8	L'influence du paramètre "Nombre de classes" sur la classification par L'algorithme Fuzzy-C-Means, pour $m = 1.5$	58
3.9	L'influence du paramètre " m " sur la classification par L'algorithme Fuzzy-C-Means, pour un Nombre de classes = 6.....	59
3.10	Les prédécesseurs du pixel traité dans l'étiquetage en composantes connexes.....	59
3.11	Détection de contours selon notre méthode (1 ^{ière} phase).....	61
3.12	Détection de contours selon notre méthode (2 ^{ième} et dernière phase).....	61
3.13	Détection de contours selon Canny (a), Sobel (b) et Prewitt (c).....	61
3.14	Illustration de la première approche de segmentation automatique.....	67
3.15	Image test de l'application (a) et ses deux images référence : (b) régions, (c) contours....	67
3.16	Processus de la segmentation et du calcul des critères de performance.....	68
3.17	Résultats de la segmentation en régions de l'image test pour les valeurs des deux paramètres d'action: $NC = \{2, 3, 4, 6, 8\}$, $m = \{1.5, 2, 3.5, 4, 5.7\}$	69
3.18	Résultats de la segmentation en contours correspondant aux différents résultats de la segmentation en régions.....	70
3.19	Influence du Nombre de classes et de l'indice flou m sur le nombre de régions de l'image segmentée.....	71
3.20	Influence du Nombre de classes et de l'indice flou m sur les critères supervisés de l'évaluation de la segmentation en régions.....	71

3.21	Influence du Nombre de classes et de l'indice flou m sur les critères non supervisés de l'évaluation de la segmentation en régions.....	72
3.22	Influence du Nombre de classes et de l'indice flou m sur les critères supervisés de l'évaluation de la segmentation en contours.....	73
3.23	Schéma général de la deuxième approche de la segmentation automatique.....	75
3.24	Organigramme de la méthode appliquée de la deuxième approche de la segmentation automatique.....	76
3.25	Les trois étapes du contrôleur flou.....	77
3.26	Les fonctions d'appartenance des entrées du contrôleur flou.....	78
3.27	Les fonctions d'appartenance des sorties du contrôleur flou.....	78
3.28	Résultats finaux de la deuxième approche de l'exemple de test.....	78
4.1	Les outils utilisés pour l'acquisition des images cytologiques.....	82
4.2	Illustration du logiciel d'acquisition d'images microscopiques 'Motic Images Plus 2.0'.....	82
4.3	Résultats de l'application de la première approche : exemples de la 1 ^{ière} à la 6 ^{ième} image.....	83
4.4	Résultats de l'application de la première approche : exemples de la 7 ^{ième} à la 12 ^{ième} image.....	84
4.5	Résultats de l'application de la deuxième approche : exemples de la 1 ^{ière} à la 6 ^{ième} image.....	86
4.6	Résultats de l'application de la deuxième approche : exemples de la 7 ^{ième} à la 12 ^{ième} image.....	87
4.7	Résultats de l'application de la première approche : exemples de la 13 ^{ième} à la 15 ^{ième} image.....	88
4.8	Résultats de l'application de la première approche : exemples de la 16 ^{ième} à la 19 ^{ième} image.....	89
4.9	Résultats de l'application de la deuxième approche : exemples de la 13 ^{ième} à la 16 ^{ième} image.....	90
4.10	Résultats de l'application de la deuxième approche : exemples de la 17 ^{ième} à la 19 ^{ième} image.....	91

Introduction

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

Dans le domaine médical, l'utilisation des images est à présent considérée comme indispensable pour des raisons de facilité de stockage et aussi pour disposer de techniques d'analyse des images automatiques ou semi-automatiques grâce à des systèmes informatiques. Ces systèmes permettent de proposer aux praticiens une nouvelle façon de travailler en obtenant de nouvelles mesures par des techniques quantitatives et objectives. Le challenge est de taille, la réalisation de systèmes informatiques aidant le médecin doit permettre de sécuriser le diagnostic, le rendant ainsi plus fiable. Les conséquences peuvent être nombreuses. L'établissement d'un diagnostic fiable peut permettre par exemple d'améliorer la qualité du dépistage des cancers et donc de favoriser la prévention.

Cette recherche de qualité dans l'établissement d'un diagnostic est très présente en anatomie et cytologie pathologiques. Dans le domaine médical, l'anatomie pathologique (ou anatomo-pathologie) est considérée comme une discipline médicale qui permet la reconnaissance des anomalies des cellules et des tissus d'un organisme, appelées lésions, pour effectuer le diagnostic des maladies (notamment le cancer), porter un pronostic, et plus généralement en comprendre les causes et les mécanismes.

En anatomie pathologique, on distingue deux types d'examen : l'**histologie** qui est l'observation de la coupe d'un tissu, et la **cytologie** qui est l'examen d'un étalement de cellules. Le rôle du cytologiste consiste en un repérage et une évaluation visuelle de toutes les cellules présentes sur une lame. Son but principal est d'établir un diagnostic, qui doit être le plus fiable possible, en détectant les cellules anormales ou suspectes. Ceci étant traduit par une déformation du noyau ou du cytoplasme de la cellule. Cette recherche manuelle des prélèvements cytologiques est un travail difficile, fatigant, coûteux en facteur temps et relativement complexe.

Une approche prometteuse est d'aider le cytologiste dans sa recherche des cellules anormales des prélèvements effectués. Le principe est de récupérer ces prélèvements et les acquérir en images afin de les traiter de façon à lui simplifier la tâche. Ceci revient à lui fournir une image plus claire et plus signifiante en appliquant une opération de segmentation qui a pour but de repérer les noyaux et les cytoplasmes des cellules. Une fois que l'image segmentée est fournie, le travail du cytologiste, qui consiste à repérer les cellules malignes, devient moins lourd et moins coûteux en facteur temps. Ceci donne à l'étape de segmentation une place très importante dans le diagnostic et la prise de décision. Par conséquent et pour assurer une segmentation fiable et meilleure nous devons évaluer le résultat issu de cette étape. C'est dans ce cadre que de nombreuses littératures ont été portées sur les différentes approches menées sur

l'évaluation de la segmentation d'images. Et c'est dans cette voie que nous avons cherché à fournir au cytologiste la meilleure segmentation qui soit.

Ce qui fait que dans notre étude nous nous sommes focalisé sur l'étape de la segmentation d'images appliquée sur des images cytologiques, en essayant le long de notre recherche d'établir un système automatique qui, à partir des résultats obtenus, réalise une étape d'évaluation grâce à des critères de performance qui ne sont autres que les critères d'évaluation, pour chercher la meilleure segmentation. Nous avons mis en œuvre de deux approches pour deux systèmes de segmentation automatique. La première approche consiste à choisir le meilleur résultat de la segmentation parmi plusieurs segmentations établies. Quant à la deuxième approche, elle corrige la segmentation en temps réel, et cela en partant d'une première segmentation. Le processus de ce système s'arrête lorsque nous atteignons une certaine satisfaction de la qualité de la segmentation traduite par un critère de performance ou encore une combinaison entre plusieurs critères de performance. Ce dernier système de segmentation automatique est basé sur la technique du contrôle flou, une technique créée par Zadeh en 1965. Pour la qualification du résultat de la segmentation, ces deux systèmes sont basés sur un calcul de critères d'évaluation, appelés aussi critères de performance, qui quantifient le degré de qualité du résultat de la segmentation. Dans la littérature, certains critères ont été définis pour des images à niveaux de gris. Pour les critères dédiés à la segmentation en régions, nous les avons adaptés pour qu'ils soient applicables sur des images couleur, vu que les images cytologiques de notre application sont des images couleur. Les deux systèmes que nous avons élaborés fournissent en leur sortie et ainsi au cytologiste une image segmentée prête à être étudiée et analysée. Il est évident que l'image segmentée est plus facile à traiter que l'image originale. Pour l'opération de segmentation nous avons considéré une approche région et une approche contour.

Dans le souci d'une bonne compréhension, ce présent mémoire est partagé en quatre chapitres. Dans le premier chapitre nous donnons des généralités sur la notion d'image et sur le principe de son acquisition, aussi nous présentons une brève classification des méthodes de segmentation. Et comme nous l'avons déjà évoqué vu que le deuxième système automatique établi repose sur la théorie du contrôle flou, cela nous a mené à donner le principe de la théorie des ensembles flous et du contrôle flou. Au deuxième chapitre nous avons classifié les différents critères d'évaluation de la segmentation d'images en deux grandes classes, les critères qui peuvent être appliqués sur les méthodes de segmentation approche régions et ceux qui s'appliquent sur les techniques de segmentation approche contours. Chacune des deux classes a été divisée en deux autres sous-classes, critères supervisés et non supervisés. Le troisième chapitre détaille les deux systèmes de segmentation automatiques que nous avons élaborés ; chacun prenant en entrées quelques critères d'évaluation choisis avec soin, et agissant en sortie sur les paramètres d'action de la méthode de segmentation utilisée en application. Le dernier chapitre rassemble les différents résultats que nous avons obtenus en appliquant les systèmes automatiques sur quelques images cytologiques ainsi que sur d'autres types d'images.

Chapitre 1

Généralités

*"Connaître, ce n'est point démontrer,
ni expliquer. C'est accéder à la vision."
Antoine de Saint-Exupéry*

1.1 Introduction

Le traitement de l'image, comme son nom l'indique, consiste à traiter et analyser l'image afin d'en tirer et interpréter les informations contenues dans l'image en question. Il passe par différentes étapes importantes qui forment la chaîne de traitement d'images. Il s'agit de [1,2]: l'acquisition de l'image, le filtrage qui constitue le prétraitement, la segmentation considérée comme le cœur du traitement, et enfin la prise de décision ou le diagnostic. Ceci est résumé sur la figure (Fig. 1.1). L'étape de segmentation fait l'objet de ce mémoire.

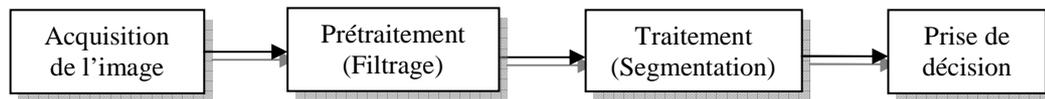


Fig. 1.1 Les différentes étapes du traitement d'image.

Dans le présent chapitre, nous expliquerons de manière succincte les principales théories abordées et utilisées le long de notre travail de recherche. Il s'agit principalement de l'acquisition de l'image (§ 1.2), du principe de la segmentation d'images précisément couleur (§ 1.3) et de la théorie de la logique floue (§ 1.4).

1.2 Acquisition de l'image

1.2.1 Qu'est-ce qu'une image ?

Le mot image, du latin imago (représentation, portrait, fantôme, copie), désigne la représentation visuelle d'un objet par différents moyens ou supports, dessin, image numérique, peinture, photographie. Ce qui fait que l'image représente généralement un objet 3D sur une surface plane. Au préalable, nous souhaitons que l'image soit le reflet le plus fidèle possible de l'objet, ceci est lié directement à la qualité du système d'acquisition d'image. Si par exemple l'objet est un point, suite à une qualité imparfaite ou pas fiable du système d'imagerie, l'image de ce point sera alors une tâche d'une certaine dimension sur l'image obtenue.

Une image numérique se distingue d'une image analogique par le fait que les informations sont regroupées sous forme d'une matrice de nombres représentant un phénomène physique. La numérisation convertit le signal (amplitude d'écho, densité optique,...) en une valeur numérique, et pour cela le signal est échantillonné. Cependant une image numérique est une image constituée de points appelés pixels (de l'anglais *picture element*) et dont la couleur est définie par un nombre codé sur un certain nombre de bits (Fig. 1.2).

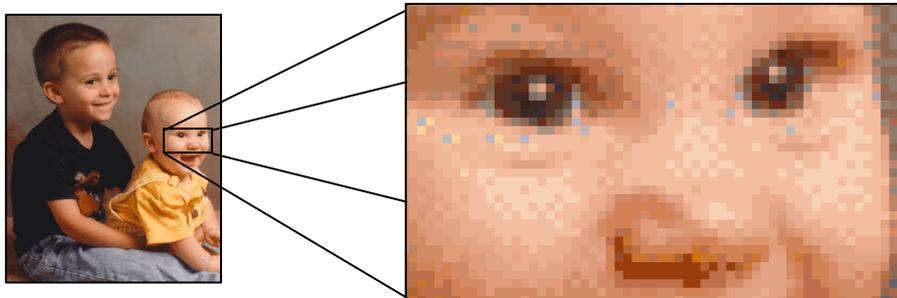


Fig. 1.2 Numérisation d'une image couleur.

1.2.2 Comment acquérir une image ?

En première approche, numériser une image [3-7] revient à représenter son contenu par un ensemble structuré de données numériques, de telle sorte qu'on puisse reproduire, à partir de ces données, une image aussi fidèle que possible au modèle d'origine. Comme les images doivent être représentées par un grand nombre de valeurs numériques, la structuration des données, c'est-à-dire l'attribution d'une signification à chacune de ces valeurs, va avoir beaucoup d'importance dans le codage. Cette structure prend en compte l'organisation des données, et définit le modèle de représentation utilisé pour ces images. La numérisation des images ne peut donc se faire sans une *modélisation* préalable. Le modèle retenu en général est bien connu, il procède de la manière suivante :

- Quand il s'agit d'images animées, on décompose les variations de l'image en une succession d'images fixes, à une fréquence de 10, 12, 24, 25 ou 30 images fixes par seconde.
- Les images fixes sont elles-mêmes décomposées en une matrice de cellules, en général carrées. Ces cellules représentent alors les unités élémentaires de l'image c'est-à-dire les *pixels*.
- Chaque pixel est caractérisé par une couleur (unique, puisque le pixel est considéré comme indivisible).

En théorie, numériser une image revient donc à numériser les informations de couleur pour chaque pixel, à le représenter par des valeurs numériques ayant une signification précise, et à structurer les données produites dans un ensemble cohérent et réutilisable. Dans la pratique, tout n'est pas si simple. Pour numériser, il faut pouvoir mesurer, et donc passer par des instruments de mesure et des capteurs. Par exemple, la situation est très différente selon qu'on numérise directement l'image d'un objet ou qu'on passe par l'intermédiaire d'une caméra vidéo :

Les instruments numérisant des images fixes, comme les scanners, sont en général conçus pour produire directement des données compatibles avec la modélisation. Ils utilisent des capteurs permettant de numériser les couleurs au niveau de chaque pixel. Pour numériser des images venant d'une source vidéo (caméscope, caméra vidéo, magnétoscope, programme diffusé), on doit raisonner différemment : l'opération consiste à numériser un signal vidéo, considéré comme un flux d'informations, avec pour objectif de savoir le restituer le plus fidèlement possible. On peut numériser ce signal sans tenir compte de sa structure interne, ou au contraire s'appuyer, pour faciliter le travail, sur la modélisation de l'image déjà présente dans le signal. En effet, bien que de nature analogique, un signal vidéo a une structure très précise qui

correspond à un découpage en une succession d'images et pour chaque image, à un découpage en lignes d'écran. La modélisation des images induites est légèrement différente de celle qu'on a évoquée plus haut (on ne descend pas au niveau du pixel), mais il est assez facile de passer d'un modèle à l'autre. En conséquence, les procédés de numérisation sont différents puisque c'est un signal vidéo variable dans le temps qu'on numérise, et non les informations couleur de chaque pixel. Ce genre de numérisation des images vidéo ne fait pas l'objet de notre travail, c'est pour cela que nous n'allons pas trop nous étaler dessus.

Cependant en se focalisant sur les images fixes, l'étude de l'étape d'acquisition passe inmanquablement par le système d'acquisition qui fait référence à l'œil. On peut utiliser des webcams, des appareils photo, des caméras industrielles, des caméras infrarouges, etc. En médecine, on utilise des imageurs *IRM* (Imagerie par Résonance Magnétique), *TEP* (Tomographie par Émission de Positrons), scanner *X*, échographie Doppler, échographie, scintigraphie, microscope numérique, etc (Fig. 1.3).

Tous ces systèmes peuvent être comparés à des capteurs. Il ne faut pas oublier qu'il y a une étape de conversion analogique/numérique. C'est souvent cette étape qui limite et définit la résolution de l'image. L'une des caractéristiques intéressantes de ces capteurs est la taille du plus petit élément qui est le pixel, mais aussi l'inter-corrélation de deux éléments voisins : plus cette inter-corrélation est faible, meilleure est l'image.

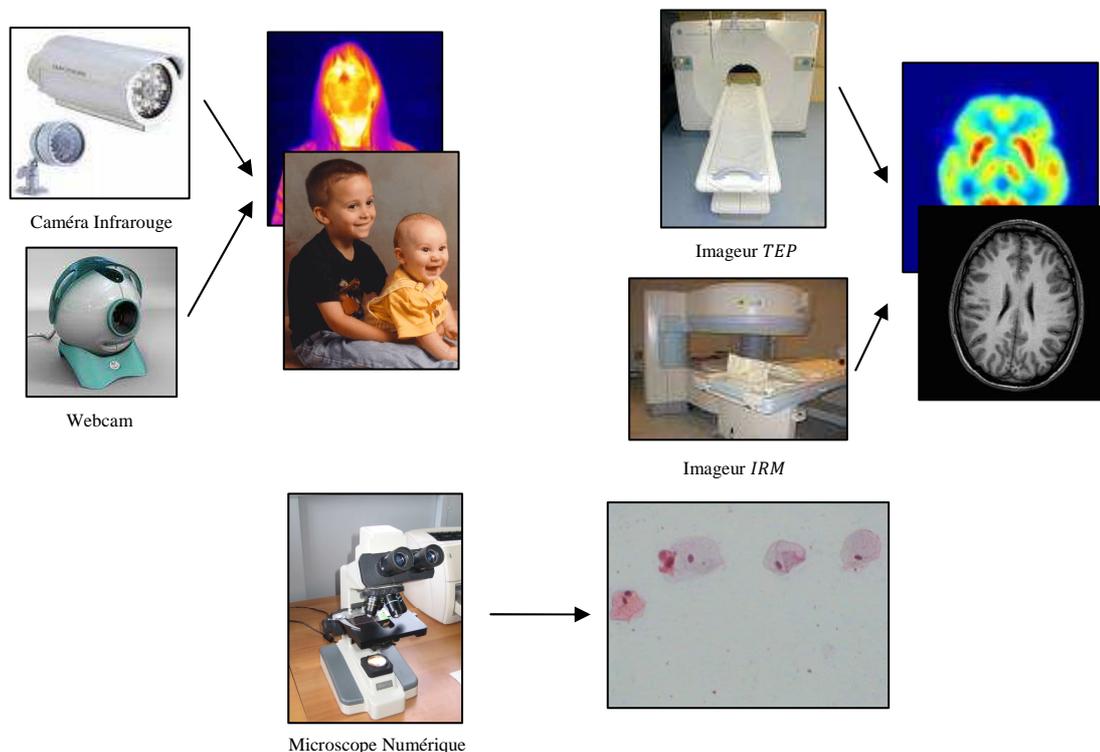


Fig. 1.3 Exemples d'outils d'acquisition d'images.

Comme nous l'avons déjà dit, l'image numérique est traduite par une matrice. Cette matrice contient les intensités en niveaux de gris des différents pixels pour les images noir et blanc ou encore les trois composantes "couleur" des pixels pour les images couleur (Fig. 1.4). Pour cela de différents espaces couleur ont été définis, ce qui a conduit à une littérature importante sur de nombreux espaces de représentation des couleurs [3,8]. Le choix de l'espace de représentation à utiliser dépend des travaux entrepris. Par exemple si nous désirons simuler le système visuel humain, c'est-à-dire considérer la couleur d'un point de vue perceptif, notre choix se portera sur des espaces comme *CIELab* (Commission Internationale de l'éclairage) ou *CIEluv* (défini en fonction de *CIELab*). Cependant dans le domaine du traitement d'images, la

priorité est donnée à un aspect "mesurable" de la couleur, dans ce cas le choix s'orientera beaucoup plus vers des espaces comme : *RVB*, *TLS* (Teinte, Saturation, Lumière), le système visuel hypothétique [3].

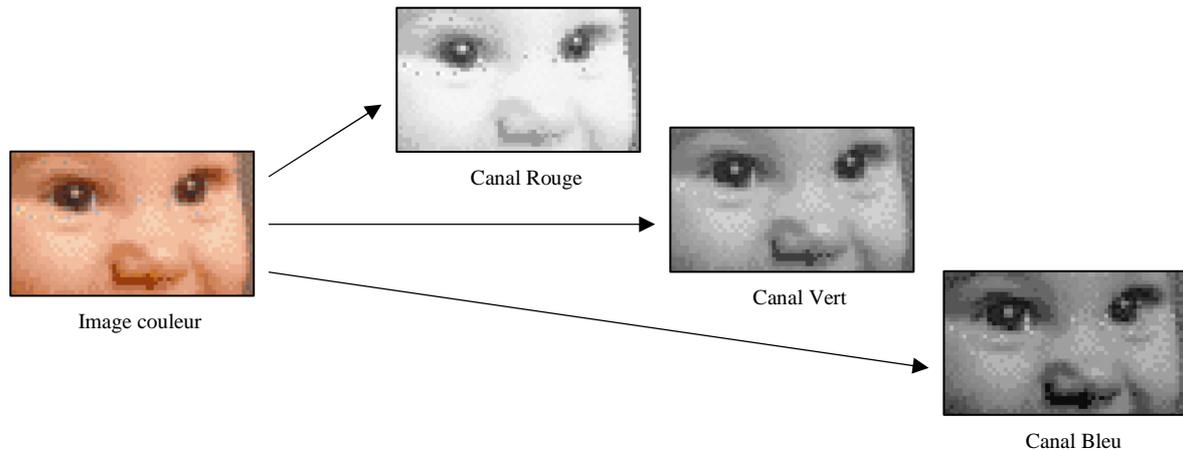


Fig. 1.4 Représentation d'une image couleur dans un espace couleur (cas de l'espace *RVB*).

Dans notre étude nous nous sommes intéressés aux images cytologiques dont l'acquisition se fait par le microscope numérique. Cependant la microscopie ne se conçoit pas uniquement comme une chaîne de mesure dans laquelle le microscope constitue un élément parmi d'autres ; si certaines images sont particulièrement esthétiques, les images constituent avant tout un résultat porteur d'information. Il convient donc d'utiliser des systèmes permettant de capter des images sans en dénaturer les informations. Actuellement la grande majorité des images sont acquises par des biologistes à l'aide de caméra *CCD*. Dans le prochain paragraphe nous allons évoquer le principe d'acquisition des images couleur via une description des capteurs couleur *CCD* qui servent à la numérisation des images [8].

1.2.3 Principe des dispositifs d'acquisition d'images couleur

Un dispositif d'acquisition d'images [5-8] capture une information lumineuse et la convertit en un signal électrique analogique. Ce signal peut être échantillonné, quantifié et stocké dans un fichier informatique sous la forme d'une image numérique. Afin de pouvoir analyser et traiter sans encombre une image, il est fortement demandé à l'opérateur de maîtriser la phase d'acquisition de l'information portée en image. Comme tout processus de mesure, non seulement le capteur, mais également sa mise en œuvre sont déterminants quant à la qualité du résultat de l'acquisition. Ceci dit qu'un capteur médiocre ne fournira que des mesures approximatives et bruitées, pendant qu'un capteur performant délivrera des mesures de qualité dans des conditions adéquates. En fait, la phase d'acquisition conditionne et fixe les limites de l'utilisation des images numériques. Un capteur à la résolution inadaptée peut par exemple conduire à la perte d'informations cruciales. D'une autre part, une image trop bruitée risque d'être source d'erreurs de mesure ou de diagnostic. Si en outre, l'information couleur est déterminante dans une application, non seulement il faut veiller à la qualité de son codage lors de l'acquisition, mais il est également nécessaire de se pencher sur sa gestion au fil des équipements. L'idéal serait de pouvoir garantir un rendu des couleurs fidèle de la scène d'origine aux différents supports de reproduction. Même si un long chemin a été parcouru depuis l'apparition de la télévision couleur, il reste encore beaucoup à faire avant d'atteindre cet idéal.

En fait, un dispositif d'acquisition d'images est construit sur la base d'un composant dit le photodétecteur dont le rôle est de transformer l'énergie lumineuse en énergie électrique. Le passage d'une image optique à son correspondant électronique repose généralement sur deux étapes : la photodétection associée à une phase de balayage.

La photodétection exploite l'effet photoélectrique c'est-à-dire les modifications des propriétés électriques d'un milieu solide ; modifications initiées par interaction avec des photons incidents. Suivant la nature du milieu, l'effet photoélectrique se traduit de différentes manières :

- La photo transmission où des électrons sont émis par le matériau (en général un métal) lorsque sa surface est éclairée.
- La photoconduction dans laquelle le flux lumineux (énergétique) incident instantané augmente la conductivité du matériau (un semi-conducteur homogène).
- La création des paires qui se traduit par l'interaction des photons avec un matériau hétérogène, homojonction *PN* ou hétérojonction de type *MOS* (Métal Oxyde Semi-conducteur), modifiant les niveaux d'énergie des atomes et donnant ainsi une naissance à des charges mobiles : des paires électron-trou.

La phase de balayage permet d'analyser et d'exploiter l'effet photoélectrique inhérent au matériau composant le photodétecteur. Par exemple dans les caméras à tube, l'image photonique est formée sur un matériau photodétecteur. La conductivité du photodétecteur, proportionnelle aux flux incident, est analysée par un faisceau d'électrons balayant séquentiellement et cycliquement la couche photosensible. Dans le cas des caméras dont le capteur est composé de photoéléments tels des hétérojonctions *MOS*, les charges mobiles sont recueillies grâce à des circuits dédiés, pilotés par un signal d'horloge. Ce signal d'horloge permet de balayer l'ensemble des éléments photosensibles en vue de traduire le signal lumineux d'entrée (image projetée sur le capteur) en un signal électrique exploitable. Dans les caméras dites *CCD* (charged-Coupled Device) (Fig. 1.5 : image prise de [8]), la photodétection est réalisée par des hétérojonctions *MOS* organisées en barrettes ou en matrice et le balayage se fait par l'intermédiaire de registres à décalage analogique appelés circuits à transfert de charges. De nos jours, la technologie *CCD* est de plus en plus répandue que ce soit pour les applications industrielles, scientifiques ou grand public.

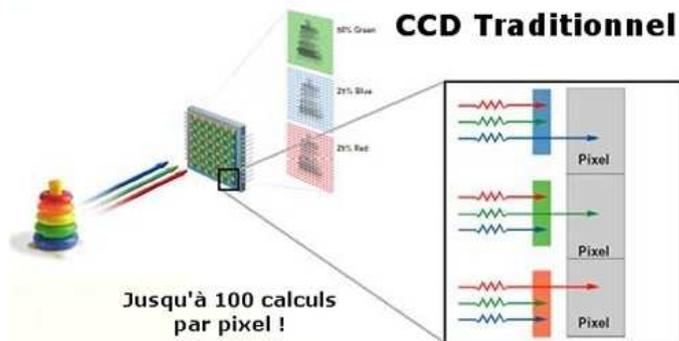


Fig. 1.5 Illustration du principe des caméras *CCD*.

Cependant au cours de l'acquisition de l'image, chaque photoélément d'un capteur *CCD* fournit un nombre de charges proportionnel au flux reçu. En outre, la scène projetée sur une barrette ou une matrice d'hétérojonctions *MOS* est numérisée spatialement en raison de la nature discrète du détecteur. Afin de garantir la compatibilité des caméras *CCD* avec les caméras à tube et les formats vidéo classiques, le signal obtenu à la suite de la phase de balayage est, d'une part, converti soit en une tension soit en un courant, qui soit mesurable et, d'autre part, interpolé pour combler les espaces entre photoéléments. Pour construire une image numérique, le signal analogique délivré par la caméra doit être échantillonné et quantifié. Cette opération repose classiquement sur un convertisseur analogique/numérique (*CAN*). Il est juste à noter qu'il existe plusieurs types de caméras *CCD* : les caméras linéaires, les caméras matricielles mono-*CCD*, les caméras matricielles tri-*CCD* et les caméras multispectrales.

1.3 La segmentation d'images

Conceptuellement, la segmentation consiste à extraire de l'image des primitives soit de type contour, soit de type région. Ces primitives seront exploitées ultérieurement pour effectuer de la reconnaissance de formes, du recalage, de la mise en correspondance, de la compression, etc. La segmentation n'est donc pas un objectif en soi mais une étape située en amont de dispositifs d'interprétation d'images, de reconstruction tridimensionnelle, de codage, etc. Cependant la segmentation a pour but de rassembler des pixels entre eux suivant des critères prédéfinis. Les pixels sont ainsi regroupés en régions qui constituent une partition de l'image. Il peut s'agir de séparer par exemple les objets du fond. Dans notre étude, il s'agit de séparer le noyau et le cytoplasme du fond de l'image cytologique. Cependant on reconnaît deux approches de segmentation, qui sont l'approche région et l'approche contour [1,2,9-16] :

- **La segmentation en régions :**

Les méthodes appartenant à cette famille manipulent directement des régions. Soit elles partent d'une première partition de l'image qui est ensuite modifiée, en divisant ou regroupant des régions, dans ce cas on parle alors de méthodes de type décomposition ; soit elles partent de quelques régions, qui sont amenées à croître par incorporation de pixels jusqu'à ce que toute l'image soit couverte, et on parle alors de méthodes par croissance de régions.

- **La segmentation en contours :**

La détection de contours est une méthode de segmentation destinée à définir les limites des différentes régions ou objets dans une image. Une autre méthode consiste à classer les points de l'image suivant leur appartenance à une région ou à un objet. La nature de l'image à traiter et le domaine d'application, interviennent dans la définition d'un contour et déterminent des critères de choix entre différentes techniques de détection.

Cependant la couleur étant une information que l'on attache naturellement aux régions, on a pensé à l'utiliser pour segmenter des images, avec l'espoir que les régions ainsi formées soient plus significatives que celles obtenues par une segmentation sur la seule information de niveau de gris [3].

A la différence du prétraitement, qui transforme l'image couleur en une autre couleur, la segmentation transforme l'image couleur soit en une image binaire contours/non contours, soit en image de régions dans laquelle tous les pixels d'une même région sont affectés d'une même étiquette. Il y a donc nécessairement passage des trois composantes à une seule composante. Cette étape peut être vue comme la fusion de sources d'information. Cette fusion intervient, soit au début du traitement afin de réduire l'espace couleur à un espace monochrome, soit à la fin du traitement. Il existe trois approches possibles pour le traitement des images couleur en vue de la segmentation :

- Passage d'une image couleur à une image monochrome, cela peut se faire par une transformée ou par une quantification. On a alors à disposition tout l'arsenal des méthodes de segmentation monochrome.
- Approche marginale : les composantes sont traitées séparément, les trois résultats sont ensuite fusionnés.
- Approche vectorielle : chaque pixel est traité comme un vecteur dans l'espace couleur. Les primitives sont extraites en prenant en comptes les trois composantes.

Les variations de couleur dans une image correspondent soit à des variations des propriétés physiques des surfaces observées, soit à des modifications de la géométrie des objets de la scène. Ainsi la présence de zones d'ombre, des modifications de l'orientation des objets ou variations de réflectance ou d'absorption lumineuse des surfaces observées, induisent des variations de couleur. Ces variations seront plus au moins détectées selon l'espace colorimétrique dans lequel s'effectue la segmentation.

La littérature foisonne de méthodes de segmentation mais aucune n'est valable pour tout type d'image. Il est à noter que le choix d'une méthode dépend souvent des connaissances a priori sur l'image et repose sur différents aspects :

- Extraction des contours ou extraction de régions,
- Présence ou non de texture ou de bruit,
- Choix de l'espace couleur et éventuellement d'une métrique dans cet espace,
- But recherché : extraire tous les objets, obtenir des contours localisés ou formant une chaîne fermée de contours, isoler des régions pertinentes, etc.

1.4 La théorie de la logique floue

1.4.1 Définition et petit historique

Dans la logique classique, les variables gérées sont Booléennes. C'est à dire qu'elles ne prennent que deux valeurs 0 ou 1. Quant à la logique floue elle a pour but de raisonner à partir de connaissances imparfaites qui opposent résistance à la logique classique. Pour cela la logique floue se propose de remplacer les variables booléennes par des variables floues.

En fait c'est depuis longtemps qu'on recherche à maîtriser les incertitudes et les imperfections inhérentes à la nature. Et la première réelle manifestation de la volonté de formaliser la prise en compte des connaissances incertaines fut le développement de la théorie des probabilités à partir du XVII siècle. Mais les probabilités ne peuvent maîtriser les incertitudes psychologiques et linguistiques. On est donc passé des développements des théories de probabilité subjective (dans les années 50) à celles de l'évidence (dans les années 60). Puis la Logique Floue est apparue en 1965 à Berkeley dans le laboratoire de Lotfi Zadeh avec la théorie des sous-ensembles flous puis en 1978 avec la théorie des possibilités. Ces deux théories constituent aujourd'hui ce que l'on appelle Logique Floue. La Logique Floue permet la formalisation des imprécisions dues à une connaissance globale d'un système très complexe et l'expression du comportement d'un système par des mots. Elle permet donc la standardisation de la description d'un système et du traitement de données aussi bien numériques qu'exprimées symboliquement par des qualifications linguistiques [17-19].

1.4.2 Les sous-ensembles flous

Un sous-ensemble flou F est défini sur un ensemble de valeurs U , appelé le référentiel. Il est caractérisé par une fonction d'appartenance définie comme suit :

$$\mu: x \in U \rightarrow \mu(x) \in [0,1]$$

Cette fonction d'appartenance quantifie le degré d'appartenance de chaque élément de l'ensemble U à F .

Pour mieux comprendre, nous donnons un exemple d'évaluation de la température de l'eau d'un récipient par les mots : Froide, Tiède et Chaude. La fonction d'appartenance de l'ensemble de valeur U aux différents sous-ensembles flous (Froide, Tiède, Chaude) peut être représentée sur (Fig. 1.6 -a). Sa version en logique classique figure sur (Fig. 1.6 -b).

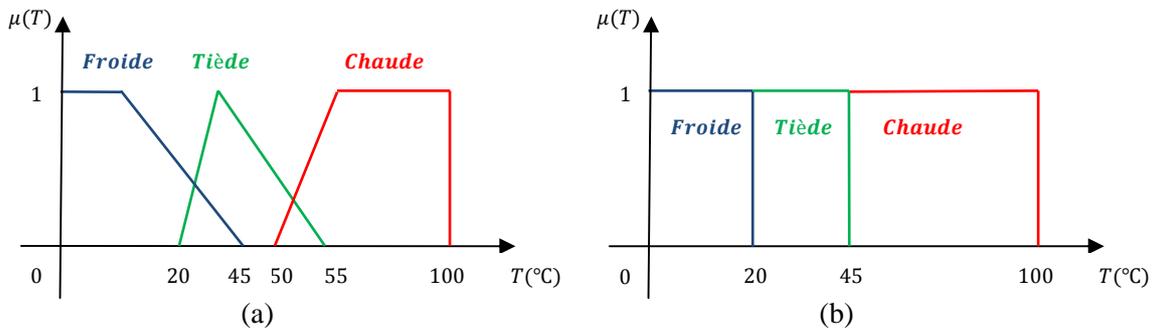


Fig. 1.6 Fonction d'appartenance : (a) logique floue, (b) logique classique.

On constate que la logique classique ne peut utiliser que le 0 et le 1 ainsi l'eau est d'abord totalement froide puis tiède et enfin chaude. En logique floue nous pouvons observer la représentation graphique des trois fonctions d'appartenance : Froide, Tiède et Chaude. Ces fonctions nous permettent de superposer sur des plages de température données les qualificatifs froide et tiède ainsi que tiède et chaude. On se rapproche donc du raisonnement humain.

1.4.3 Opérateurs de base sur les sous-ensembles flous

La théorie mathématique sur les sous-ensembles flous définit de nombreuses opérations sur ces sous-ensembles et sur les fonctions d'appartenance qui rendent ces notions utilisables. Nous présentons ici les opérateurs de base de cette théorie que nous avons utilisés dans notre application. Supposons que A et B sont deux sous-ensembles flous et $\mu(A)$ et $\mu(B)$ leurs fonctions d'appartenance respectivement. On définit :

- Le complémentaire de A, par la fonction d'appartenance (Fig. 1.7 -a) :
$$\mu(\bar{A}) = 1 - \mu(A)$$
- Le sous-ensemble A et B, par la fonction d'appartenance (Fig. 1.7 -b):
$$\mu(A \cap B) = \min(\mu(A), \mu(B))$$
- Le sous-ensemble A et B, par la fonction d'appartenance (Fig. 1.7 -c):
$$\mu(A \cup B) = \max(\mu(A), \mu(B))$$

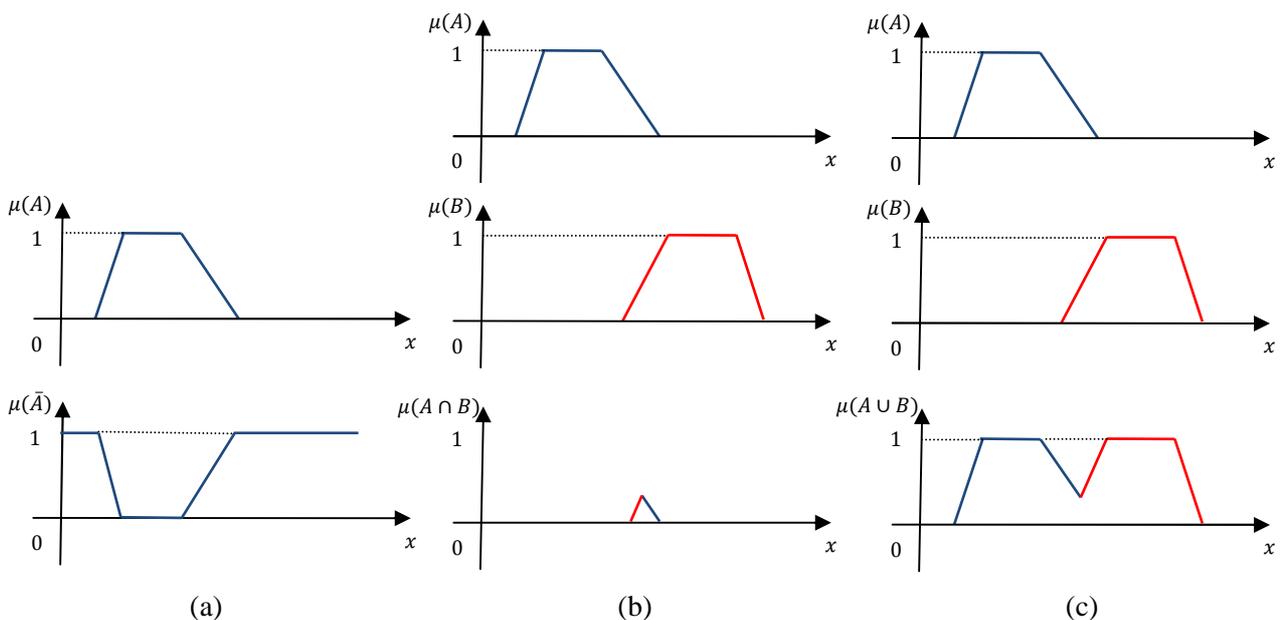


Fig. 1.7 Illustration des opérateurs de base.

1.4.4 La commande floue

La Commande floue est l'application la plus utilisée de la logique floue. Elle consiste à remplacer les algorithmes de réglage conventionnels par des règles linguistiques du type : SI la voiture qui me précède est proche ET que je roule vite ALORS il faut freiner rapidement. Ainsi on obtient un algorithme linguistique qui se prête mieux que les méthodes traditionnelles à la commande d'un processus. Le schéma général d'une Commande Floue est représenté sur (Fig. 1.8).

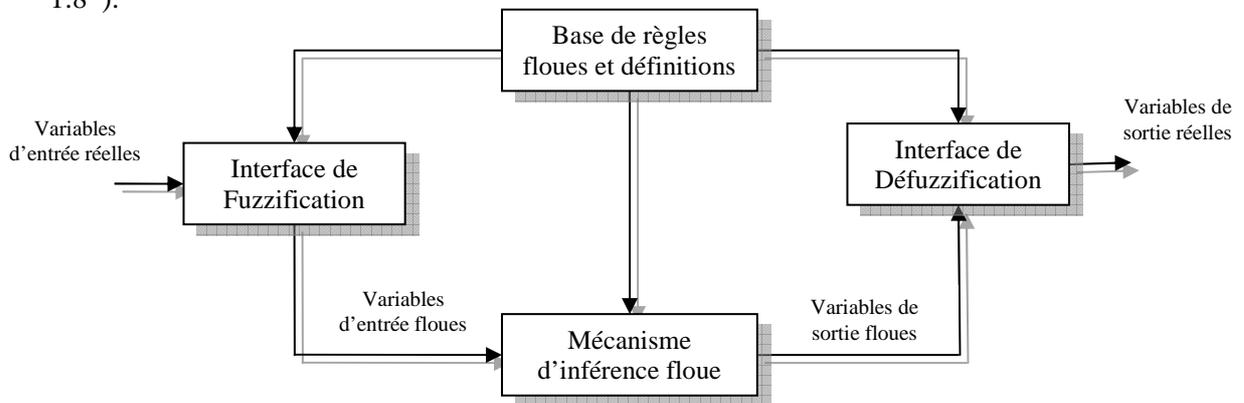


Fig. 1.8 Schéma général d'une commande floue.

On procède tout d'abord à la partition en sous-ensembles flous des différents univers de discours (ou référentiels) que le système impose. Ensuite on détermine **la base de règles** qui va caractériser le fonctionnement désiré du système. Puis il faut transformer les variables réelles, c'est à dire celles qui ont une réalité physique, en variables floues. On appelle cette étape **la fuzzification** (de fuzzy signifie flou en anglais). On utilise alors ces variables floues dans **un mécanisme d'inférence** qui crée et détermine les variables floues de sortie en utilisant les opérations sur les fonctions d'appartenance. Enfin, on opère à **la défuzzification** qui consiste à extraire une valeur réelle de sortie à partir de la fonction d'appartenance du sous-ensemble flou de sortie établi par le mécanisme d'inférence.

1.4.5 La fuzzification

L'opération de fuzzification permet de passer du domaine réel au domaine flou. Elle consiste à déterminer le degré d'appartenance d'une valeur x_0 à un ensemble flou. Sur l'exemple de la figure (Fig. 1.9), le degré d'appartenance de x_0 est de 0.3 au sous-ensemble Froide, de 0.7 au sous-ensemble Tiède et de 0 au sous-ensemble Chaude. Ainsi la syntaxe de formulation du degré d'appartenance de x_0 aux différents sous-ensembles flous, s'écrit comme suit :

$$\mu(x_0) = 0.3 * Froide + 0.7 * Tiède + 0 * Chaude$$

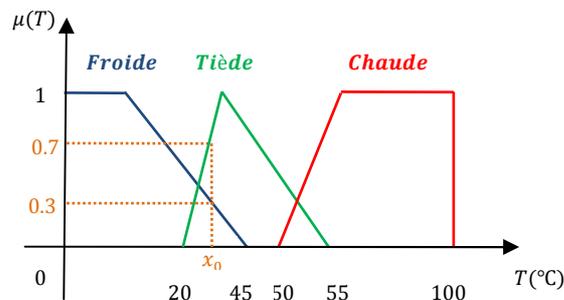


Fig. 1.9 Exemple de fuzzification.

Pour que le système soit cohérent il faut que la somme des degrés d'appartenance aux différents ensembles flous soit égale à 1.

1.4.6 L'inférence floue

Le mécanisme d'inférence floue le plus couramment utilisé est celui dit de Mamdani. Il représente une simplification du mécanisme plus général basé sur l'implication floue. Ce mécanisme se base sur l'application des règles floues. Une base de règles floues est composée de règles qui sont généralement utilisées en parallèle, mais peuvent également être enchaînées dans certaines applications. Les bases de règles floues, tout comme les systèmes experts classiques, fonctionnent en s'appuyant sur une base de connaissance issue de l'expertise humaine. Une règle est du type : *SI* « prédicat » *ALORS* « conclusion ». On donne l'exemple d'un système de réglage d'une chaudière comme suit:

« *SI* pression forte *ET* température élevée *ALORS* ventilation forte et soupape grande ouverte ».

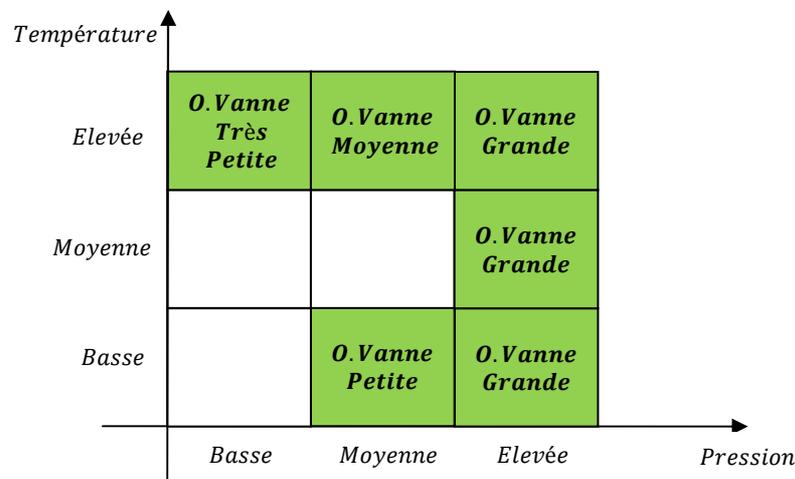


Fig. 1.10 Représentation de l'implication de l'exemple donné.

Donc les bases de règles floues, dans leur cas général, sont définies par des fonctions d'appartenance sur les variables du système, et par des règles qui peuvent être écrites textuellement.

Chaque règle fait appel à des entrées et des sorties qui peuvent être différentes, comme le montre l'exemple suivant :

Règle1 : *SI* pression élevée *ALORS* vanne grande ouverte,

Règle2 : *SI* pression moyenne *ET* température élevée *ALORS* vanne moyenne,

Règle3 : *SI* pression moyenne *ET* température basse *ALORS* petite ouverture de la vanne,

Règle4 : *SI* pression basse *ET* température élevée *ALORS* très petite ouverture de la vanne.

Schématiquement, on peut représenter les zones d'action des règles et leur recouvrement de cet exemple sur la figure (Fig. 1.10).

Si par exemple nous avons une température de 17°C et une pression de 2,5 bars, le mécanisme de l'inférence floue est détaillé sur la figure (Fig. 1.11).

A la fin de l'inférence, l'ensemble flou de sortie est déterminé mais il n'est pas directement utilisable pour donner une information précise à l'opérateur ou commander un

actionneur. Donc il est nécessaire de passer du monde flou au monde réel, c'est la défuzzification.

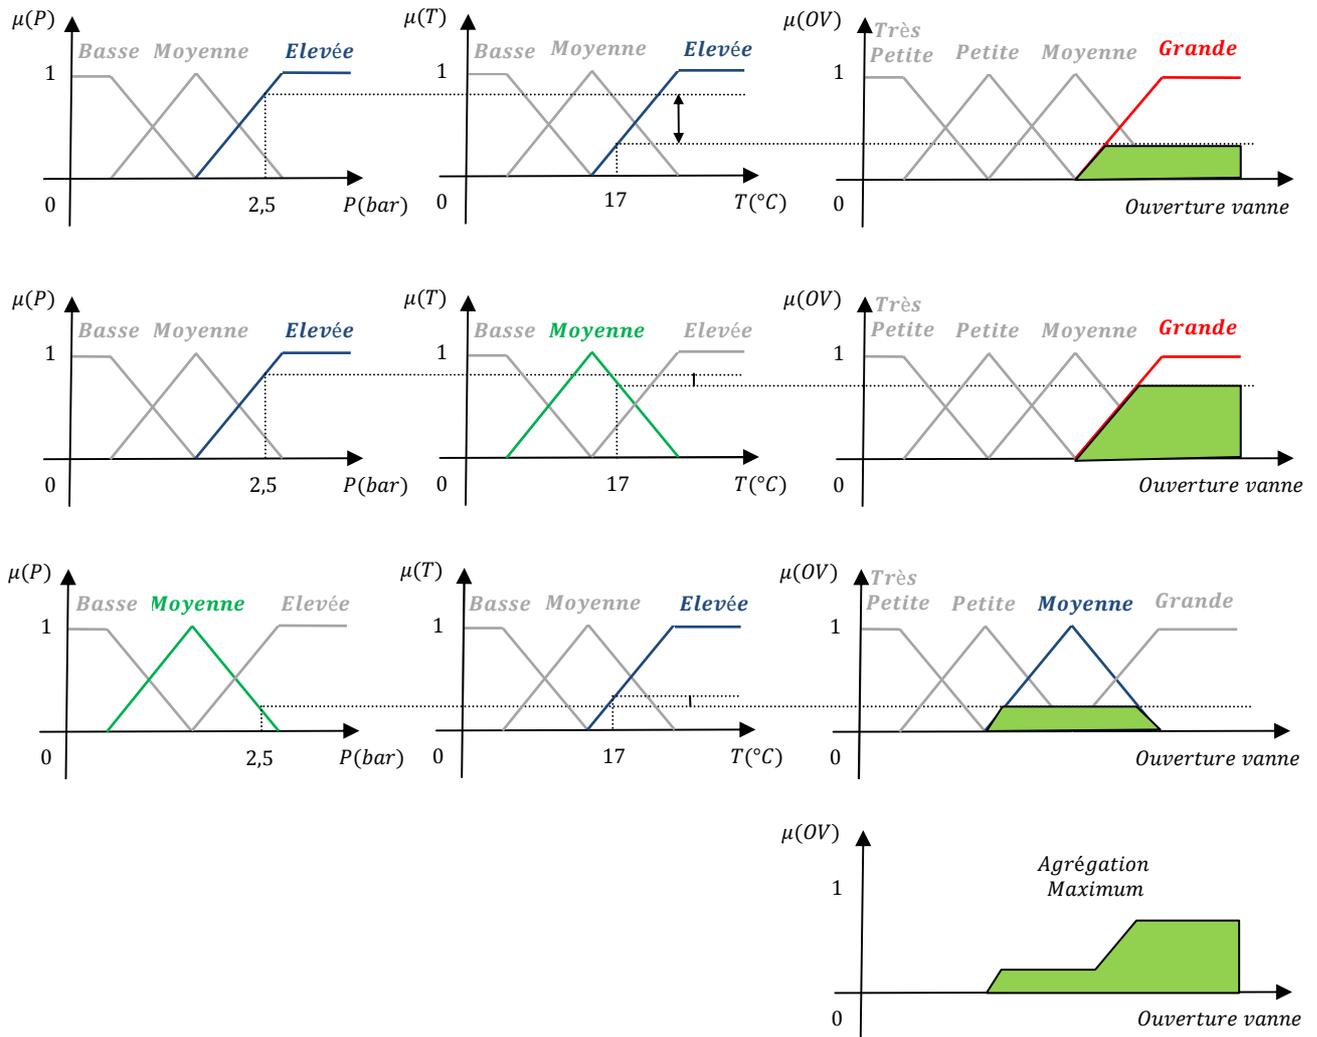


Fig. 1.11 Mécanisme d'inférence floue pour des valeurs de deux entrées.

1.4.7 La défuzzification

Le but de la défuzzification est d'extraire une valeur réelle y_0 à partir de la fonction d'appartenance $\mu(y)$ du sous-ensemble de sortie. Nous prenons l'exemple de la figure (Fig. 1.12 -a) qui représente la fonction d'appartenance issue de la sortie de l'inférence floue. La méthode la plus simple et la plus approximative est alors de prendre en compte le premier maximum de la fonction $\mu(y)$ (Fig. 1.12 -b). La deuxième est de considérer la moyenne des maximums de la fonction d'appartenance (Fig. 1.12 -c). La troisième méthode est l'extraction barycentrique de la valeur y_0 , qui consiste à faire une moyenne des valeurs du référentiel pondérées par leur degré d'appartenance. Cette méthode est encore peu coûteuse en calcul et donne de bons résultats (Fig. 1.12 -d). La dernière méthode qui est de loin la plus utile est celle qui consiste à prendre en compte le centre de gravité de la surface délimitée par la fonction d'appartenance (Fig. 1.12 -e).

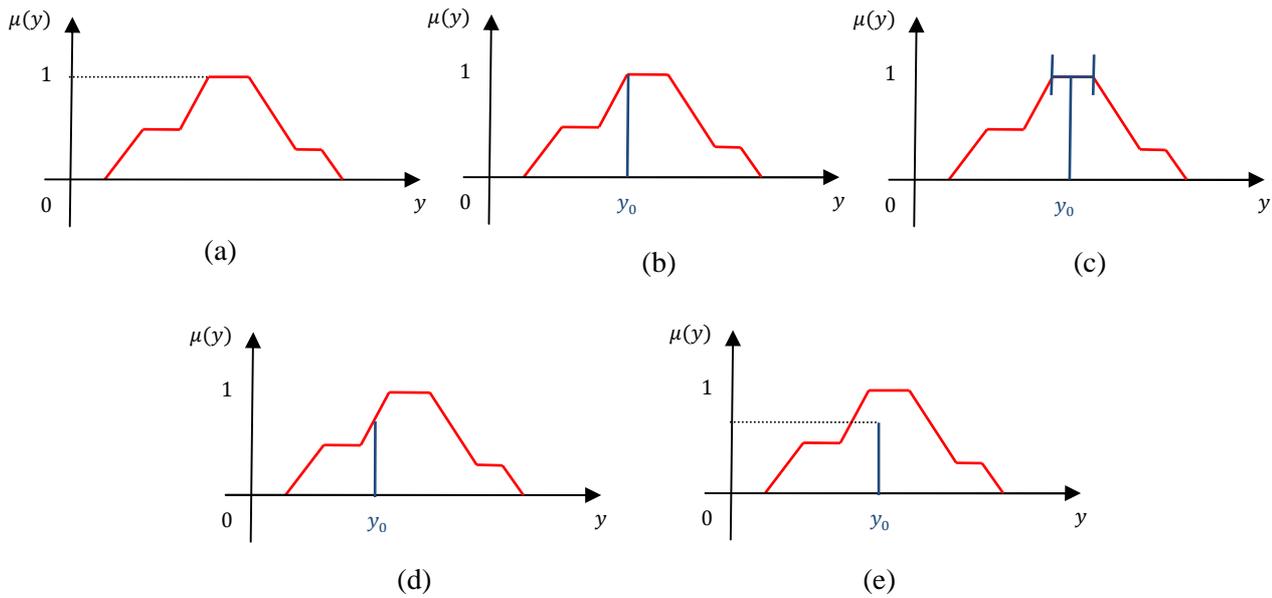


Fig. 1.12 Illustration des techniques basiques de la défuzzification.

1.5 Récapitulatif

Dans ce chapitre nous avons introduit les différentes approches et théories que nous avons utilisées au cours de ce travail de mémoire de magister. Nous avons vu que l'étape de segmentation constitue le moteur du traitement d'image, ce qui la rend une étape très importante. Dans le but d'assurer la qualité de cette opération, nous avons pensé à en mesurer la qualité. Ceci peut se faire grâce à l'évaluation de la segmentation. Ce qui a nous mené à établir un état de l'art sur les différents critères d'évaluation de la segmentation. Ceci va faire l'objet du prochain chapitre.

Chapitre 2

Évaluation de la Segmentation

"Ne me dites pas que ce problème est difficile. S'il n'était pas difficile, ce ne serait pas un problème."

Ferdinand Foch

2.1 Introduction

Devant le foisonnement de méthodes développées depuis plusieurs décennies pour la segmentation des images, le problème de l'évaluation est devenu crucial. Définir une bonne segmentation demeure difficile d'autant plus que la solution dépend du but recherché. La segmentation n'est pas une fin en soi et l'idée de qualité absolue, indépendante de toute application, est certainement vide de sens. Nous pensons donc que la seule façon réaliste d'aborder l'évaluation de la segmentation est d'envisager une mesure de l'adéquation d'un résultat à un besoin formulé. Or une des caractéristiques essentielles d'un besoin en segmentation, si ce n'est pas la caractéristique essentielle, est le niveau de détail attendu : l'application requiert-elle une description fine ou à grands traits de la scène ?.

Ce qui entraîne que dans la chaîne du traitement d'images, une étape d'évaluation de la segmentation d'images qui soit objective et quantitative est indispensable pour qualifier et donner un sens au résultat de la segmentation. Et cela dans le cadre où elle interprète le degré de la qualité de la segmentation effectuée par un critère de mesure de qualité dit aussi indicateur de performance, qui se base sur les caractéristiques contenues dans l'image résultat de la segmentation.

Suite à la nécessité de procéder à l'évaluation de la segmentation, une grande littérature s'est lancée dans ce sens et a proposé de différents critères d'évaluation de la segmentation. Ils se sont basés soit sur la méthode de la segmentation utilisée ou sur la disponibilité d'une image de référence. Pour classer ces différents critères et pour les rendre plus faciles à appliquer, Zhang a défini trois grandes classes d'approches d'évaluation de segmentation d'images [20]. Il s'agit de :

- **méthodes analytiques**, qui traitent les algorithmes de segmentation directement en considérant les principes, les besoins, l'utilité, la complexité, etc., de ces algorithmes. Contrairement à ce qu'il pourrait paraître, l'étude analytique ne peut obtenir l'ensemble des propriétés caractérisant les algorithmes de segmentation. D'une autre part l'analyse et l'expérience démontrent que les méthodes analytiques peuvent seulement rajouter quelques informations à celles que les autres méthodes apportent, et ceci est rarement utilisé dans l'isolation.

- **méthodes empiriques de justesse (méthodes d'évaluation non supervisée)**, qui évaluent la performance des algorithmes indirectement en jugeant le résultat des images segmentées avec un certain degré de mesure de qualité établie selon l'intuition humaine. Plusieurs mesures de justesse ont été proposées pour couvrir les différents aspects d'une *idéale* ou *bonne* segmentation. Ces mesures de qualité ont été classifiées en trois groupes:

G1 - l'uniformité intra-régions
 G2 - le contraste Inter-région
 G3 - la forme de région

- **méthodes empiriques de divergence (méthodes d'évaluation supervisée)**, qui calculent la différence entre l'actuelle image segmentée et l'image segmentée correctement ou idéalement (l'image de référence appelée aussi vérité terrain) pour établir les performances des algorithmes de segmentation. En d'autres termes, ces méthodes cherchent à déterminer la distance entre l'image segmentée et l'image de référence. Des résultats expérimentaux comparatifs ont démontré que les méthodes empiriques de divergence sont plus efficaces que celle de justesse. Cinq groupes de mesures sont distingués :

D1 - nombre de pixels mis-segmentés
 D2 - position de pixels mis-segmentés
 D3 - nombre d'objets dans l'image
 D4 - valeurs caractéristiques des objets segmentés
 D5 - quantités Miscellaneous

Dans notre étude, et afin de faciliter la tâche à l'expérimentateur de s'orienter davantage dans le choix du critère approprié à utiliser dans l'application de la segmentation, et cela bien sûr pour mieux évaluer le résultat de la segmentation, nous avons essayé de donner une autre classification des critères d'évaluation de la segmentation. En se basant beaucoup plus sur les études comparatives données dans [21-26], nous avons défini une nouvelle classification des critères d'évaluation en deux classes et qui tient en compte la méthode de la segmentation utilisée, il s'agit de:

- **Évaluation de segmentation régions**, elle rassemble tous les critères qui s'appliquent dans l'évaluation du résultat de la segmentation région, que ce soit des images à niveaux de gris ou images couleur. Nous y trouvons les critères supervisés et non supervisés.
- **Évaluation de segmentation contours**, du même principe cette classe s'adresse à l'évaluation des différentes méthodes de segmentation en contours, pour images monochromes ou couleurs. Aussi, elle se partage en critères supervisés et non supervisés.

Cela sera présenté tout au long de ce présent chapitre. En complément, nous allons préciser au dernier paragraphe de ce même chapitre les critères qui peuvent être destinés aux deux approches de segmentation. Dans cette classification nous n'avons pas abordé l'évaluation des algorithmes de segmentation. Nous y détaillerons la notion de l'évaluation supervisée et non-supervisée. Nous notons que nous avons gardé la même notation des formules des références sources. Aussi, nous avons symbolisé chaque critère par les trois premières lettres de son auteur.

2.2 Évaluation de la segmentation en régions

Selon sa définition, le but de la segmentation région est de partitionner l'image en principales classes ou régions qui donnent une signification des objets contenus dans l'image rassemblant tous les pixels dont les caractéristiques se rapprochent (intensité, position, forme..),

et cela en faisant en sorte que les caractéristiques des pixels de chaque région fluctuent autour de la moyenne de leurs caractéristiques. Plusieurs critères qui interprètent cette caractéristique ont été définis sous forme de critères d'uniformités ou de contrastes entre les régions de l'image résultat. Il est à noter que ces critères peuvent être supervisés ou non supervisés.

2.2.1 Critères supervisés

Le principe de l'évaluation supervisée est de qualifier le résultat de la segmentation par rapport à une connaissance a priori qui peut bien être exprimée en une vérité terrain ou des connaissances sur les objets à identifier. Une vérité terrain peut être prédéfinie par une image synthétique qui apporte une grande précision par rapport au but de la segmentation voulu, ou encore tracée subjectivement par un expert du domaine dont la confiance que l'on peut lui accorder doit être bien connue et estimée. L'évaluation dans cette branche peut être faite grâce à des critères qui mesurent la dissimilarité entre l'image résultat et l'image de référence. Cette dissimilarité doit être pertinente en tenant compte de la taille des régions mal classées, de l'information spatiale concernant la localisation des pixels qui la constituent, et cela tout en vérifiant la définition d'une distance prédéfinie. Pour cette partie nous allons présenter tous les critères qui, comme nous l'avons déjà dit, calculent la mesure d'erreurs de classification. Leur principe est de mesurer le degré de dissimilarité entre l'image résultat de la segmentation et l'image de référence déjà donnée qui est 'vérité terrain'. Ceci va être détaillé par la suite.

2.2.1.1 Critère de Yasnoff

Yasnoff a travaillé sur l'erreur de classification pour donner plusieurs formules qui mesurent le degré de justesse de la classification en régions. Ceci revient à dire que les classes sont supposées connues, ça revient à savoir pour chaque classe d'un résultat de la segmentation la classe qui doit lui être associée dans la segmentation de référence.

La matrice dite de confusion, C_{ij} avec $i, j=1..n, j=1..n$, où n est le nombre de classes de la segmentation, calcule les erreurs de classification. Les termes diagonaux C_{ii} représentent les pixels bien classés tandis que les termes $C_{ij} (i \neq j)$ représentent le nombre de pixels étiquetés i alors que réellement ils appartiennent à la classe j . Les deux mesures d'erreur proposées par Yasnoff sont données par les formules suivantes:

Pour chaque classe nous avons,

$$YAS1(k) = 100 \times \frac{\sum_{i=1}^n (C_{ik} - C_{kk})}{\sum_{i=1}^n C_{ik}}$$

Où : $\sum_{i=1}^n C_{ik}$ représente le nombre total de pixels de la classe k et C_{kk} le nombre de pixels correctement classés dans la classe k .

$$YAS2(k) = 100 \times \frac{[\sum_{i=1}^n C_{ki}] - C_{kk}}{\sum_{j=1}^n \sum_{i=1}^n C_{ij} - \sum_{i=1}^n C_{ik}}$$

Où : $\sum_{i=1}^n C_{ki}$ représente le nombre total de pixels étiquetés avec k ,

Et $(\sum_{j=1}^n \sum_{i=1}^n C_{ij} - \sum_{i=1}^n C_{ik})$ est le nombre de pixels de l'image n'appartenant pas à la classe k .

Ces deux indicateurs permettent de prendre en considération les erreurs de classification classe par classe, mais ne tiennent pas compte des informations spatiales sur les pixels mal classés. Pour cela, Yasnoff propose un autre indicateur fondé sur le calcul d'un taux d'erreur pour un pixel mal classé a proportionnel à la distance entre ce pixel et le plus proche

pixel appartenant à la classe à laquelle a aurait dû être affecté. L'erreur de segmentation entre un résultat de segmentation I_R et sa référence $I_{R_{ref}}$ est alors définie comme suit :

$$YAS3 = \frac{100}{card(I_R)} \times \sqrt{\sum_{a \in I_R, a \notin R_a} \min_{b \in R_a} d(a, b)}$$

Où $R_a \in I_{R_{ref}}$ correspond à la région à laquelle devrait appartenir le pixel $a \in I_R$ et $d(a, b)$ correspond à la distance entre un pixel a n'appartenant pas à R_a et le pixel le plus proche de $R_a \in I_{R_{ref}}$.

Ce critère présente un problème car de nombreuses configurations peuvent donner la même distance d'erreur. Par exemple, dans la figure (Fig 2.1), dans les trois situations, la distance d'erreur des pixels est la même (le nombre de pixels mal classés est le même). Or, les trois pixels mal classés du cas (a) devraient être comptés comme des pixels appartenant à l'objet, alors que ceux du cas (b) devraient être comptés comme des pixels appartenant au fond. La conséquence de ces deux cas est différente, à la fois pour la taille et la forme des objets détectés. De plus, la distance d'erreur des pixels ne permet pas de distinguer quelques pixels mal classés isolés (Fig 2.1-c) d'un cluster de pixels mal classés (Fig 2.1-b), bien que l'erreur produite par le second soit plus importante que celle produite par le premier.

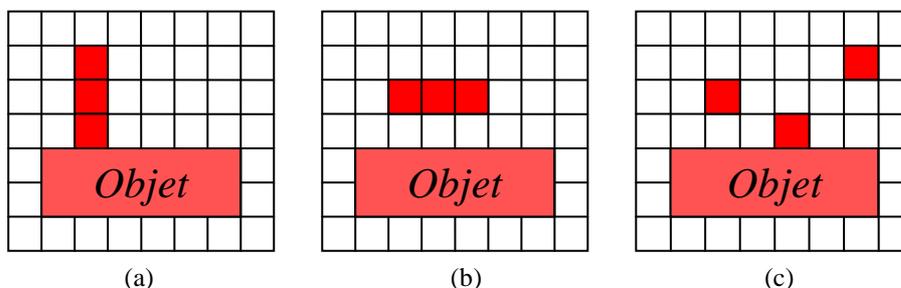


Fig 2.1 Différentes configurations ayant le même nombre de pixels mal classés et à la même distance mais d'impacts différents.

2.2.1.2 Critère de Vinet

Vinet propose une mesure de dissimilarité entre deux images qui peuvent bien être deux images résultats ou bien une image résultat I_L et la vérité terrain $I_{L_{ref}}$. On définit la table de superposition comme étant égale à :

$$T(I_L, I_{L_{ref}}) = \{card(L_i \cap L_j^{ref}), i = 1..NL, j = 1..NL_{ref}\}$$

où $card(L_i \cap L_j^{ref})$ est le nombre de pixels étiquetés i dans L en correspondance avec les pixels j dans L^{ref} .

Avec cette table, on recherche les classes appariées de manière récursive. D'abord comme première étape on sélectionne dans le tableau les deux classes qui maximisent le terme $card(L_i \cap L_j^{ref})$. Puis, dans la table, on désélectionne tous les éléments de la ligne et de la colonne correspondant à l'élément sélectionné. Et on retourne à la première étape tant qu'il reste des éléments dans la table.

Avec les cellules sélectionnées, Vinet donne une mesure de dissimilarité. Son principe est illustré sur la figure (Fig 2.2). Soit C l'ensemble des cellules sélectionnées :

$$VIN(I_L, I_{L_{ref}}) = card(I) - \sum_C card(L_i \cap L_j^{ref})$$

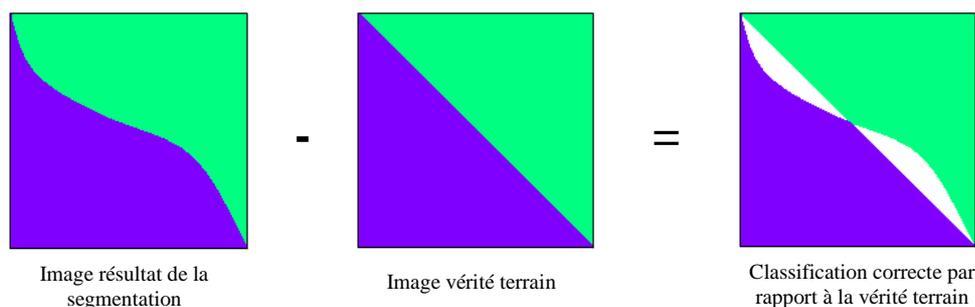


Fig 2.2 Principe du critère de Vinet.

Il est à noter que ce critère est facile à mettre en œuvre. Par contre, il n'apparie pas toutes les classes, donc il ne prend pas en compte toute l'information (entre autre la dispersion spatiale des pixels). Il part de l'hypothèse que deux classes sont à appairer si elles ont un ensemble maximal commun de pixels. Cette hypothèse est restrictive et privilégie les grandes régions.

2.2.1.3 Critère de Martin

Martin a proposé deux mesures d'erreur entre deux images résultats de segmentation.

$$MAR1(R^1, R^2) = \frac{1}{\text{card}(X)} \min \left\{ \sum_{x \in X} E(R^1, R^2, x), \sum_{x \in X} E(R^2, R^1, x) \right\}$$

$$MAR1(R^1, R^2) = \frac{1}{\text{card}(X)} \sum_{x \in X} \min \{ E(R^1, R^2, x), E(R^2, R^1, x) \}$$

Où l'erreur de raffinement local est définie comme étant :

$$E(R^1, R^2, x) = \frac{\text{card}(R(R^1, x)) - \text{card}(R(R^1, x) \cap R(R^2, x))}{\text{card}(R(R^1, x))}$$

Où : $R(R^i, x)$ est l'ensemble des pixels correspondant à la région qui contient le pixel x dans le résultat de segmentation R^i , et X le support commun aux deux images résultats de segmentation R^1 et R^2 .

L'objectif de ces critères est principalement de valider la création d'une base de segmentation experte. Cependant, ils peuvent servir à comparer des résultats de segmentation entre eux, et plus particulièrement un résultat de segmentation quelconque avec une vérité terrain experte.

2.2.1.4 Critère de Hamming

Le critère de Hamming est aussi une mesure de différence entre deux résultats de segmentation. Soient $R^1 = \{R_1^1, \dots, R_{NR^1}^1\}$ et $R^2 = \{R_1^2, \dots, R_{NR^2}^2\}$ deux résultats de segmentation d'une image I . On met en correspondance les régions de R^1 et R^2 qui ont un recouvrement maximal. L'expression de mesure directionnelle de Hamming entre R^1 et R^2 est donnée par :

$$D_H(R^1, R^2) = \sum_{i=1}^{n2} \sum_{k=1, k \neq i}^{n1} \text{card}(R_i^2 \cap R_k^1)$$

Le terme central est la somme des aires de toutes les intersections non maximales et non vides de la région R_i^2 avec les régions de R^1 . A partir de cette expression, la distance normalisée de Hamming est définie comme suit :

$$HAM(R^1, R^2) = 1 - \frac{D_H(R^1, R^2) + D_H(R^2, R^1)}{2 \times card(X)}$$

Une valeur de $HAM(R^1, R^2)$ proche de 1 traduit un fort degré de mise en correspondance.

2.2.1.5 Critère de Kara-Fallah

Soit X le support commun aux deux résultats de segmentation. La mesure de dissimilarité entre deux résultats de segmentation en régions I_{R_1} et I_{R_2} proposée par Kara-Fallah est donnée comme suit :

$$KAR(I_{R_1}, I_{R_2}) = \left[\frac{1}{card(X)} \sum_{(x,y) \in X} |f_{I_{R_1}, I_{R_2}}(x, y)|^p \right]^{\frac{1}{p}}$$

Où :

$$f_{I_{R_1}, I_{R_2}}(x, y) = \sum_{i=1}^{NR^1} d_w((x, y), R_i^1) - \sum_{i=1}^{NR^2} d_w((x, y), R_i^2) - (NR^1 - NR^2) * c$$

Avec P un entier positif, d_w une distance bornée, $c = \lim_{t \rightarrow \infty} w(t)$ sa borne supérieure et $w(t)$ une fonction continue à déterminer par l'utilisateur. L'auteur de ce critère propose par exemple : $w(t) = \frac{t}{(t+1)}$ ou $w(t) = \tan^{-1}(t)$ ou encore $w(t) = \min\{t, c\}$ avec une valeur $c > 0$ fixe.

Cette mesure permet de comparer globalement deux résultats de segmentation en régions ou en classes. L'utilisation d'une distance bornée la rend moins sensible au bruit. Un avantage de cette distance réside dans le fait qu'elle prend en compte une information spatiale concernant la localisation des pixels mal appariés. Cependant, ce critère est très coûteux en temps de calcul.

2.2.2 Critères non supervisés

L'évaluation non supervisée consiste à évaluer le résultat de la segmentation sans une connaissance a priori sur l'image désirée. Les critères non supervisés se calculent à partir des propres informations contenues dans l'image. En général ces critères sont statistiques. Dans la catégorie des critères non supervisés destinés à la segmentation régions on peut les classer en : la mesure d'uniformité, le calcul du contraste, les critères hybrides ou les critères adaptatifs.

2.2.2.1 Critère de Rosenfeld

Rosenfeld et Weszka ont proposé un critère d'évaluation avec seuillage qui utilise une mesure de bruitage pour juger les images seuillées. Le résultat indique une quantité de bruit. Moins il y a de bruit plus le résultat est supposé être bon.

2.2.2.2 Uniformité de Levine et Nazif

Le critère d'uniformité sert à quantifier le degré de ressemblance entre les différentes régions constituant l'image segmentée résultante. Les régions segmentées doivent paraître les plus homogènes possibles pour pouvoir qualifier le résultat de 'bon'.

Levine et Nazif ont défini leur critère d'uniformité intra-régions qui se base sur le calcul de la variance de la caractéristique de chaque région. Le critère global d'uniformité est calculé à partir de la mesure d'uniformité de toutes les régions constituant l'image segmentée. Il est donné par l'expression suivante :

$$LEV(I_R) = 1 - \sum_{k=1}^{NR} \frac{\sum_{(i,j) \in R_k} (g_I(i,j) - \sum_{(m,n) \in R_k} g_I(m,n))^2}{card(I) \times \left(\max_{(i,j) \in R_k} (g_I(i,j)) - \min_{(i,j) \in R_k} (g_I(i,j)) \right)^2}$$

où :

- NR est le nombre de régions,
- A est l'aire de l'image donnée par le nombre de pixels constituant l'image I ,
- R_k indique la région numéro k ,
- $g_I(i,j)$ est l'intensité du pixel de coordonnées (i,j) de l'image originale (résultat).

Par la suite Levine et Nazif ont proposé une expression générale de l'uniformité dans le sens où on peut remplacer l'intensité de niveau de gris par un autre attribut comme l'intensité couleur ou la texture ou autre. Aussi, chacune des régions peut être pondérée par l'aire qui la constitue pour pénaliser plus ou moins les régions.

2.2.2.3 Uniformité de Sahoo

Sahoo a proposé de normaliser le critère d'uniformité de Levine et Nazif, ce qui donne la formule suivante :

$$SAH1(I_R) = \sum_{k=1}^{NR} \sum_{(i,j) \in R_k} (g_I(i,j) - \bar{g}_k)^2$$

Où : $\bar{g}_k = \frac{1}{A_k} \sum_{(i,j) \in R_k} g_I(i,j)$ est l'intensité moyenne de la région R_k , où A_k est l'aire de la région R_k .

La formule finale est donnée comme suit :

$$SAH2(I_R) = 1 - \frac{SAH1(I_R)}{C}$$

Où C correspond à un facteur de normalisation qui peut bien être la taille de l'image.

2.2.2.4 Uniformité de Cochran

Reposant sur le même principe d'uniformité inter-région, Cochran a proposé un indice de confiance sur l'homogénéité des régions présentes dans une image. Il a formulé comme suit :

$$COC(I_R) = \frac{\max_{k=1..NR} \sigma_I^2(R_k)}{\sum_{k=1}^{NR} \sigma_I^2(R_k)}$$

Où $\sigma_I^2(R_k)$ correspond à la variance du niveau de gris des pixels de la région R_k de l'image originale I . Les régions sont considérées comme homogènes si $COC(I_R) < H_{lim}$. Où H_{lim} correspond à un seuil choisi arbitrairement définissant la condition limite d'homogénéité. Il est à noter que la variance peut être calculée sur n'importe quel ensemble des attributs. Et la qualité de l'évaluation est fortement dépendante du choix des attributs et du seuil.

2.2.2.5 Contraste de Levine et Nazif

Du même principe, le contraste entre régions cherche à quantifier la mesure de différence entre chaque paire de régions adjacentes, pour finalement donner le contraste global de l'image.

Levine et Nazif ont donné le contraste entre deux régions adjacentes en niveaux de gris comme étant :

$$CLEV1(R_i, R_j) = \frac{|\bar{g}_I(R_i) - \bar{g}_I(R_j)|}{\bar{g}_I(R_i) + \bar{g}_I(R_j)}$$

Aussi ils ont donné une formule de contraste de la région R_i par rapport à toutes les régions de l'image qui lui sont adjacentes, comme suit :

$$CLEV2 = \sum_{R_k \in W(R_a)} p_{R_a/R_k} CLEV1(R_a, R_k)$$

Avec : $p_{R_a/R_k} = \frac{card(F_{R_a \cap R_k})}{card(F_{R_a})}$ est le rapport longueur de frontière commune entre R_a et R_k sur le périmètre de la région R_a .

Et : $W(R_a)$ est l'ensemble des régions adjacentes de la région R_a .

Le contraste global est donné par :

$$CLEV3(I_R) = \frac{\sum_{k=1}^{NR} w_{R_k} CLEV2(R_k)}{\sum_{k=1}^{NR} w_{R_k}}$$

Où : w_{R_k} est un poids associé à la région R_k et qui peut être en fonction de l'aire de cette région.

2.2.2.6 Contraste de Zeboudj

Zeboudj a proposé une mesure reposant sur les principes conjugués du contraste inter-région maximal et du contraste intra-régions minimal calculé sur un voisinage $W(x)$ du pixel x pour un résultat de segmentation en régions. D'abord on donne les définitions suivantes :

- Le contraste entre deux pixels x et y de l'image I par :

$$c_I(x, y) = \frac{|g_I(x) - g_I(y)|}{\max_{x \in I}(g_I(x)) - 1}$$

- le contraste intérieur :

$$C_{int}(R_k) = \frac{1}{A_k} \sum_{x \in R_k} \max\{c_I(x, y), y \in W(x) \cap R_k\}$$

- le contraste extérieur :

$$C_{ext}(R_k) = \frac{1}{card(F_{R_k})} \sum_{x \in R_k} \max\{c_I(x, y), y \in W(x), y \notin R_k\}$$

Où F_{R_k} correspond à la frontière de la région R_k .

- le contraste de la région R_k est donné par l'expression suivante avec $(R_k) \in [0,1]$:

$$C(R_k) = \begin{cases} 1 - \frac{C_{int}(R_k)}{C_{ext}(R_k)} & \text{si } 0 < C_{int}(R_k) < C_{ext}(R_k) \\ C_{ext}(R_k) & \text{si } C_{int}(R_k) = 0 \\ 0 & \text{sinon} \end{cases}$$

Le contraste global de l'image est donné par la formule:

$$CZEB(I_R) = \frac{1}{A} \sum_{k=1}^{NR} A_k \times C(R_k)$$

Une région est bien segmentée si elle possède un contraste intérieur faible et un contraste extérieur sur la frontière relevée, donc une valeur de $C(R_k)$ proche de 1. L'inconvénient de ce critère est que dans les images texturées il ne prend pas correctement en compte les régions fortement texturées.

2.2.2.7 Critère de Rosenberger

Rosenberger a proposé un critère adaptatif qui estime l'homogénéité des régions de l'image segmentée de manière à maximiser l'homogénéité inter-classe et le contraste inter-classe. Ce critère a la particularité de prendre en compte le caractère uniforme ou texturé des classes segmentées. Il se base sur les deux notions suivantes :

- Les régions doivent être homogènes,
- Les régions adjacentes doivent présenter des valeurs significativement différentes pour les caractéristiques utilisées (niveau de gris, attribut couleur, etc) .

Le critère a été défini comme étant :

$$ROS(I_L) = \frac{C_{intra}(I_L) + 1 - C_{inter}(I_L)}{2}$$

Où :

- $C_{intra}(I_L)$ est la disparité intra-classes globale quantifiant l'homogénéité de chacune des classes de l'image I ,
- $C_{inter}(I_L)$ est la disparité inter-classe globale mesurant la disparité globale de chacune des classes de l'image I .

La disparité $C_{intra}(I_L)$ traduit la stabilité des statistiques des classes de l'image. Elle est calculée à partir de la disparité intra-classes $C_{intra}(L_k)$ des différentes classes $L_k \in L$:

$$C_{intra}(I_L) = \frac{1}{NL} \sum_{k=1}^{NL} \frac{card(L_k)}{card(I)} C_{intra}(L_k)$$

L'importance de la disparité intra-classes d'une classe L_k dans le calcul de la disparité intra-classes globale est proportionnelle au nombre de pixels $card(L_k)$ de cette classe. Ainsi une classe de petite taille influence moins dans le calcul de la disparité intra-classes globale.

Le principe est identique pour le calcul de la disparité globale inter-classe $C_{inter}(I_L)$ de l'image segmentée I qui mesure la disparité de chaque classe avec ses voisins :

$$C_{inter}(I_L) = \frac{1}{NL} \sum_{k=1}^{NL} \frac{card(L_k)}{card(I)} C_{inter}(L_k)$$

Dans les calculs inter et intra-classes, la nature de la classe segmentée est prise en compte, à savoir uniforme ou texturée. Un paramètre d'uniformité défini par Rosenberger permet de déterminer l'appartenance des classes à l'une de ces deux catégories.

Ainsi, les cas particuliers suivants sont obtenus pour les calculs de disparité :

a) Cas de disparité intra-classes pour des classes uniformes

Dans le cas de classes uniformes, la disparité intra-classes est donnée par l'écart-type normalisé de celle-ci :

$$C_{intra}(L_k) = \frac{2}{255} \sqrt{\frac{1}{card(L_k)} \sum_{(i,j) \in L_k} (g_I(i,j))^2 - \frac{1}{(card(L_k))^2} \left(\sum_{(i,j) \in L_k} g_I(i,j) \right)^2}$$

Cette caractéristique d'ordre 2 sur la dispersion des niveaux de gris d'une classe est suffisante pour caractériser la disparité intra-classes d'une classe uniforme.

b) Cas de disparité intra-classes pour des classes texturées

Si la classe est texturée, l'écart-type ne donne pas d'information suffisante sur l'homogénéité de celle-ci. Le processus proposé est bien plus complexe et se décompose en deux étapes principales :

1. Pour chaque classe L_k du résultat de segmentation, il faut effectuer une analyse locale de la classe par balayage d'une fenêtre d'exploration avec chevauchement maximal et calculer un vecteur d'attributs \mathbf{a} sur cette fenêtre significative. Ce vecteur est composé des attributs de texture définis par Rosenberger.
2. pour chaque classe L_k , trois calculs sont à effectuer :

- (a) soit $A = \{a^1, \dots, a^{l_k}\}$ l'ensemble de l_k vecteurs caractéristiques de la classe L_k pour l_k fenêtres, le barycentre B_k de L_k est calculé de la façon suivante :

$$B_k = \frac{1}{l_k} \sum_{1 \leq p \leq l_k} a^p$$

- (b) la disparité intra-classes de la classe L_k est ensuite déterminée de la façon suivante : on effectue une classification en deux partitions de cette classe par un algorithme des K-means. Afin d'estimer la disparité intra-classes de la classe L_k , ce résultat de classification est analysé.

La mesure de dispersion m d'une classe d'éléments dans $\Gamma = \{T_1, \dots, T_{card(\Gamma)}\}$ de barycentre B est définie comme suit :

$$m = \frac{1}{card(\Gamma)} \sum_{k=1}^{card(\Gamma)} d(B, T_k)$$

où $d(x, y)$ est la distance euclidienne.

Cette valeur quantifie l'écart moyen d'un élément de la classe à son barycentre. Soient m_1 et m_2 les mesures de dispersion de chacune des partitions P_1 et P_2 .

La disparité intra-classes est définie de la façon suivante :

$$C_{intra}(L_k) = \begin{cases} 1 & \text{si } d(B_1, B_2) > m_1 + m_2 \\ 0 & \text{sinon} \end{cases}$$

Si ces deux classes sont relativement séparées, alors la disparité intra-classes est pénalisée par la valeur maximale 1 puisqu'il existe une partition valide de la classe L_k au sens de ce critère. Dans le cas contraire, la classe L_k est considérée comme homogène et donc sa disparité intra-classes est nulle.

(c) Enfin les pixels isolés sont traités :

Soit out_k le nombre de pixels isolés de la classe L_k (n'appartenant pas à la composante connexe maximale de la région), la disparité intra-classes est mise à jour de la façon suivante :

$$C_{intra}(L_k) = C_{intra}(L_k) + \frac{out_k}{card(I)}$$

ceci permet de prendre en compte dans le calcul de la disparité intra-classes, les pixels n'appartenant pas à la composante connexe maximale de celle-ci.

La disparité intra-classes est calculée à partir de la dispersion des attributs d'une classe. Elle est pénalisée par le pourcentage de pixels isolés de l'image car une classe texturée de petite taille n'a pas vraiment de sens. Ce traitement de pixels isolés permet donc de prendre en compte de régions de très petite taille n'ayant pas de réelle signification en général.

c) Cas de la disparité inter-classe

Le procédé d'évaluation de la disparité inter-classe d'une classe est similaire à ce qui a été réalisé précédemment. En effet, au lieu d'estimer l'homogénéité d'une classe, on calcule sa disparité avec les classes voisines. La disparité inter-classe s'écrit dans ce cas, comme la moyenne de la disparité d'une classe avec ses voisines.

Pour le calcul de la disparité entre classes de types différents, elle est mise à 1 et est donc rendue maximale. Pour le calcul de la disparité entre classes de même type, le calcul est bien plus complexe. Une classe est décrite par la valeur moyenne des statistiques représentatives de la primitive. Ainsi une classe uniforme est décrite par sa moyenne de niveaux de gris et une classe texturée par le vecteur d'attributs moyen, c'est-à-dire son barycentre. La disparité entre deux primitives est alors estimée en considérant l'écart des valeurs moyennes.

Tout d'abord, la disparité D entre deux classes uniformes L_i et L_j est calculée de la façon suivante :

$$D(L_i, L_j) = \frac{|\bar{g}_i(L_i) - \bar{g}_i(L_j)|}{NG}$$

où NG est le nombre de niveaux de gris dans l'image. Cette valeur estime l'écart normalisé entre les niveaux de gris moyens de deux classes uniformes. Cette information est suffisante dans la mesure où une classe uniforme a une moyenne constante de façon générale.

La disparité entre deux classes texturées L_i et L_j se calcule de la façon suivante :

$$D(L_i, L_j) = \frac{D(B_i, B_j)}{\|B_i\| + \|B_j\|}$$

où B_k est le barycentre de la classe L_k .

Soit $V_k = \{L_1, \dots, L_{q^{(k)}}\}$ l'ensemble des classes voisines de L_k où $q^{(k)}$ représentent le nombre de classes voisines de la classe k . La disparité inter-classe de L_k s'exprime sous la forme :

$$C_{inter}(L_k) = \frac{1}{q^{(k)}} \sum_{j=1}^{q^{(k)}} D(L_k, L_j)$$

Suivant le type de primitive de chaque classe, le calcul de la dissimilarité est adapté en fonction du contexte. L'originalité de ce critère réside dans sa capacité à évaluer des résultats de segmentation d'images texturées. Initialement exprimé en classe, ce critère reste bien sûr valable pour l'évaluation de résultats de segmentation en régions.

2.2.2.8 Critère de Liu

Liu et Yang ont proposé un critère qui assure les trois propriétés heuristiques suivantes :

1. les régions doivent être uniformes et homogènes,
2. l'intérieur des régions doit être simple et sans trop de petits trous,
3. les régions adjacentes doivent présenter des valeurs significativement différentes pour la caractéristique d'uniformité.

La forme de ce critère est la suivante :

$$LIU(I_R) = \frac{1}{1000 \times \text{card}(I)} \sqrt{NR} \sum_{k=1}^{NR} \frac{e_k^2}{\sqrt{\text{card}(R_k)}}$$

Où e_k correspond à la somme des distances euclidiennes entre les vecteurs couleurs des pixels de la région R_k dans l'image segmentée. Les erreurs dans différents espaces de couleur ne sont pas comparables et pour cette raison sont ramenées à l'espace RVB. Des images en niveaux de gris peuvent aussi être utilisées. Dans ce cas, il suffit de considérer le niveau de gris au lieu des trois composantes RVB.

Le premier terme de l'équation est un facteur de normalisation qui tient compte de la taille de l'image. Le second terme pénalise les résultats ayant un grand nombre de régions (sur-segmentation). Le troisième pénalise les résultats présentant des régions non homogènes. Ce dernier terme est proportionnel au facteur d'aire car l'erreur de couleur est plus importante pour de grandes régions. Plus la valeur du critère de Liu est petite, meilleur est supposé être le résultat de segmentation. Ce critère ne requiert aucun paramètre ou seuillage.

2.2.2.9 Critère de Borsotti

Lorsque Borsotti a analysé le critère de Liu, il a identifié des limitations de cette fonction d'évaluation. En fait, ils ont montré que la présence de nombreuses régions dans l'image segmentée est pénalisée uniquement par la mesure globale \sqrt{NR} . Ainsi, dans des images très bruitées, le nombre de régions est très important. Cependant, l'erreur de chaque région tend vers zéro, ce qui fait que le critère de Liu s'approche de zéro. Ceci signifie que le résultat d'une telle segmentation est bon, et ce n'est pas le cas. Borsotti a alors modifié l'expression du critère de Liu de sorte à pénaliser les résultats de segmentation présentant beaucoup de petites régions ainsi que des régions non homogènes, pour le rendre plus sensible aux petites variations de segmentation. Il a formulé le critère suivant:

$$BOR(I_R) = \frac{\sqrt{NR}}{10^4 \times \text{card}(I)} \sum_{k=1}^{NR} \left[\frac{e_k^2}{1 + \log(\text{card}(R_k))} + \left(\frac{\chi(\text{card}(R_k))}{\text{card}(R_k)} \right)^2 \right]$$

Où $\chi(\text{card}(R_k))$ correspond au nombre de régions ayant une aire égale à $\text{card}(R_k)$.

Le corps de la somme est composée de deux termes : le premier pénalise les régions non homogènes (typiquement les grandes régions), alors que le second terme pénalise les régions dont l'aire $\text{card}(R_k)$ est égale à l'aire de beaucoup d'autres régions dans l'image segmentée (typiquement les petites).

2.3 Évaluation de la segmentation en contours

2.3.1 Critères supervisés

2.3.1.1 Erreur de sur détection

Pour mesurer la qualité d'une détection de contours, la première chose à proposer est de calculer l'écart entre les frontières obtenues de la segmentation en contours et celles théoriques. Pour effectuer de tels calculs, trois mesures d'erreur de détection ont été données :

- les erreurs de sur-détection correspondant aux pixels frontières détectés qui ne coïncident pas avec la frontière de référence,
- les erreurs de sous-détection correspondant aux pixels de la frontière de référence qui n'ont pas été détectés,
- les erreurs de localisation correspondant à la distance entre les pixels mal classés et les pixels de la frontière de référence.

Idéalement, un bon algorithme de détection de frontières devrait minimiser simultanément les erreurs correspondant à ces trois critères. En réalité, ces trois types d'erreurs sont souvent indépendants. Pour pouvoir effectuer une mesure d'évaluation de détection de frontières, l'idée est alors d'utiliser une partie ou une combinaison de ces trois types d'erreur de détection. Ces trois mesures d'erreurs donnent des indices globaux sur la qualité d'un résultat.

L'erreur de sur-détection est définie comme étant :

$$SUR(I_F, I_{ref}) = \frac{card(I_F) - card(I_F \cap I_{ref})}{card(I_F) - card(I_{ref})}$$

Quand $SUR = 0$ il n'y a pas de sur-segmentation $I_F \subset I_{ref}$, et quand $SUR = 1$ on a $I - I_{ref} \subset I_F$.

2.3.1.2 Erreur de sous détection

L'erreur de sous-détection est donnée par la formule:

$$SOUS(I_F, I_{ref}) = \frac{card(I_{ref/F}^{cont})}{card(I_{ref}^{cont})}$$

Quand $SOUS = 0$ il n'y a pas de sous-segmentation $I_F \subset I_{ref}$, et quand $SOUS = 1$ alors $I_F \cap I_{ref} = \emptyset$.

2.3.1.3 Erreur de localisation

Quant à l'erreur de localisation, elle est donnée comme suit:

$$LOC(I_F, I_{ref}) = \frac{card((I_{ref/F}) \cup (I_{F/ref}))}{card(I)}$$

Quand $LOC = 0$, il n'y a pas de mauvaise localisation de frontières $I_F = I_{ref}$, et quand $LOC = 1$ alors $I_F \cap I_{ref} = \emptyset$ et $I_F \cup I_{ref} = I$.

2.3.1.4 Erreur quadratique moyenne

L'erreur quadratique moyenne (Root Mean Square) est une des premières mesures de divergence proposée exprimée dans l'espace de Fourier. Soient deux images de même taille I_1 et I_2 possédant un support commun X . L'écart entre ces deux images en niveaux de gris est alors quantifié par :

$$RMS(I_1, I_2) = \sqrt{\frac{1}{\text{card}(X)} \sum_{(i,j) \in X} (g_{I_1}(i,j) - g_{I_2}(i,j))^2}$$

Où $g_{I_k}(i,j)$ est le niveau de gris du pixel (i,j) de l'image I_k .

2.3.1.5 Distance L_q

L'erreur quadratique moyenne a été étendue aux distances L_q :

$$L_q(I_1, I_2) = \left(\frac{1}{\text{card}(X)} \sum_{(i,j) \in X} (g_{I_1}(i,j) - g_{I_2}(i,j))^q \right)^{\frac{1}{q}}$$

où $q \in \mathbb{N}^*$ est le degré de cette distance.

Il est à noter que la notion de distance fait correspondre une bonne segmentation en contours à une petite valeur de la mesure de distance.

Les mesures de distance quadratique ont été complétées par de différentes distances provenant de l'interprétation probabilistique d'images. Il s'agit de la distance de Küllback, la distance de Bhattacharya et la distance de Jensen.

2.3.1.6 Distance de Küllback

La distance de Küllback est donnée comme suit :

$$KUL(I_1, I_2) = \frac{1}{\text{card}(X)} \sum_{(i,j) \in X} (g_{I_1}(i,j) - g_{I_2}(i,j)) \times \log \left(\frac{g_{I_1}(i,j)}{g_{I_2}(i,j)} \right)$$

2.3.1.7 Distance de Bhattacharya

Bhattacharya a donné la définition suivante :

$$BHA(I_1, I_2) = -\log \left(\frac{1}{\text{card}(X)} \sum_{(i,j) \in X} \sqrt{g_{I_1}(i,j) \times g_{I_2}(i,j)} \right)$$

2.3.1.8 Distance de Jensen

Le calcul de la distance de Jensen repose sur les entropies de Rényi. Cette distance est donnée comme suit :

$$JEN(I_1, I_2) = J \left(\frac{I_1 + I_2}{2}, I_1 \right)$$

où :

$$J(I_1, I_2) = H_\alpha(\sqrt{I_1 \times I_2}) - \frac{H_\alpha(I_1) + H_\alpha(I_2)}{2}$$

Avec H_α correspondant aux entropies de Rényi paramétrées par α entier tel que $\alpha > 3$, donné comme étant :

$$H_\alpha(I_1) = \frac{1}{1-\alpha} \ln \left(\sum_{(i,j) \in I_1} (g_{I_1}(i,j))^\alpha \right)$$

Ces différentes mesures de distance (L'erreur quadratique moyenne, la distance L_q , la distance de Küllback, la distance de Bhattacharya et la distance de Jensen) prédisent de façon très imprécise les déformations perceptibles. Comme elles n'intègrent pas l'information spatiale sur les pixels, elles peuvent donner lieu à des valeurs aberrantes. Par exemple, si les images I_1 et I_2 représentent le même objet sombre sur fond clair, mais ayant subi une translation sur I_2 la valeur du RMS par exemple va devenir très importante. Ce type de mesure a le désavantage de ne pas prendre en compte d'éventuels déplacements géométriques.

2.3.1.9 Mesure de Fram et deutsch

Fram et Deutsch ont été parmi les premiers à proposer une technique d'évaluation de la performance de détecteurs de frontières en présence de bruit. Afin de pouvoir comparer différents détecteurs de frontières, deux mesures quantitatives ont été proposées. Les calculs se font sur une zone notée C autour de la frontière sur la carte de référence I_{ref} . Une détection optimale doit extraire un contour de la frontière dans la zone C par pixel de I_{ref}^{cont} .

Le premier paramètre est alors défini comme le rapport entre le nombre des pixels frontière détectés dûs au signal et le nombre de pixels frontière détectés dûs au bruit et au signal. Le nombre des pixels dûs au bruit est normalisé afin de le rendre indépendant de la taille de l'image.

$$FRA1(I_F, I_{ref}) = \frac{card(N_i)}{N_i + N_b + N_e}$$

où : N_i est le nombre de pixels frontière de I_{ref}^{cont} dans C ,

N_b est le nombre de fausses détections dans C (par exemple le cas de détection de plusieurs pixels au lieu d'un seul),

N_e est le nombre de I_F^{Cont} en dehors de C .

Le deuxième paramètre est une mesure de la distribution de vrais pixels frontière détectés le long de la frontière. Il est donné comme suit :

$$FRA2(I_F, I_{ref}) = \frac{N_l}{N_l + N_2}$$

où : N_l est le nombre de lignes de C ,

N_2 est le nombre de lignes avec deux pixels dans C .

Ces deux indices $FRA1$ et $FRA2$ sont compris entre 0 et 1. $FRA1$ vaut 1 s'il n'y a pas de bruit détecté sur toute l'image et $FRA2$ vaut 1 s'il n'y a pas de lacune dans la frontière extraite. Un inconvénient majeur de cette méthode réside dans le fait que l'on est obligé d'avoir une cartographie de frontières fermées et d'épaisseur d'un pixel afin d'appliquer correctement les critères, or ce n'est que rarement le cas.

2.3.1.10 Distance de Hausdorff

La distance de Hausdorff représente une mesure de la distance spatiale entre deux ensembles de pixels, et dans le cas qui nous intéresse, de deux cartes de frontières I_F et I_{ref} . La distance de Hausdorff est définie comme suit :

$$HAU(I_F, I_{ref}) = \max \left(h(I_F, I_{ref}), h(I_{ref}, I_F) \right)$$

Où :

$$h(I_F, I_{ref}) = \max_{a \in I_F^{cont}} \min_{b \in I_{ref}^{cont}} \|a - b\|$$

Si $h(I_F, I_{ref}) = \delta$, cela signifie que tous les pixels de I_{ref}^{cont} sont à une distance inférieure à δ de quelques pixels de I_F^{cont} .

Si $HAU(I_F, I_{ref}) = \partial$, cela signifie que tous les pixels de I_F^{cont} sont à une distance inférieure à ∂ de quelques pixels de I_{ref}^{cont} .

2.3.1.11 Distance de Huttenlocher

Huttenlocher a exploité la distance de Hausdorff et d'autres mesures pour comparer des images binaires. Ils a ainsi défini la distance suivante :

$$HUT(I_F, I_{ref}) = K^{th}_{a \in I_F^{cont}} \min_{b \in I_{ref}^{cont}} \|a - b\|$$

Où : $1 \leq K \leq \text{card}(I_F^{cont})$ et $K^{th}_{a \in I_F^{cont}}$ représente le $K^{ième}$ pixel de I_F^{cont} , l'ordre des pixels frontière de I_F^{cont} étant totalement arbitraire.

Cette mesure est théoriquement très intéressante car ne connaissant aucune corrélation entre les pixels de l'image, elle donne une bonne mesure de similarité entre deux résultats de segmentation. Par contre, elle est très sensible au bruit et son temps de calcul est important.

2.3.1.12 Distance de Baddeley

Baddeley a proposé une variante de la distance de Hausdorff pour les images binaires. Soit X le support commun aux deux résultats de segmentation I_{F_1} et I_{F_2} . Il a donné sa première formule :

$$BAD1(I_{F_1}, I_{F_2}) = \max_{(i,j) \in (I_{F_1} \cup I_{F_2})} \left(d((i,j), I_{F_1}), d((i,j), I_{F_2}) \right)$$

Où :

$$d(x, I) = \min_{y \in I} d(x, y)$$

La deuxième formule est donnée comme suit :

$$BAD2(I_{F_1}, I_{F_2}) = \left(\frac{1}{\text{card}(X)} \sum_{(i,j) \in (I_{F_1} \cup I_{F_2})} \left| d((i,j), I_{F_1}) - d((i,j), I_{F_2}) \right|^p \right)^{\frac{1}{p}}$$

Où $p \geq 1$.

On note que la distance de Baddeley a la même complexité algorithmique que la distance de Hausdorff. Elle possède aussi une grande sensibilité au bruit. Quand p tend vers l'infini, la distance de Baddeley tend vers celle de Hausdorff. Des extensions de la distance de Baddeley ont été utilisées pour mesurer la dissimilarité entre des images en niveaux de gris. Elles étendent la distance utilisée pixel à pixel et établissent sur un voisinage, une distance locale dans un espace 3D constitué des coordonnées des pixels et leurs niveaux de gris.

2.3.1.13 Critère de Pratt

Pratt a proposé une mesure empirique de comparaison entre une carte de frontière I_F et une carte de référence I_{ref} . Cette mesure est appelée couramment dans la littérature ‘Figure of Merit’. Elle est définie par la formule suivante :

$$PRA(I_F, I_{ref}) = \frac{1}{MP} \sum_{k=1}^{card(I_F^{cont})} \frac{1}{1 + \alpha \left(d(I_F^{cont}(k), I_{ref}^{cont}) \right)^2}$$

Où $MP = \max\{card(I_{ref}^{cont}), card(I_F^{cont})\}$ et α est une constante de normalisation permettant de respecter l’inégalité : $0 \leq PRA(I_F, I_{ref}) \leq 1$.

Cette mesure est l’une des plus utilisées, bien qu’elle n’ait pas de justification théorique. Elle a quelques inconvénients connus :

- elle n’est pas symétrique : $PRA(I_F, I_{ref}) \neq PRA(I_{ref}, I_F)$,
- elle est sensible aux erreurs de sur-détection et de localisation,
- elle n’est pas sensible à la forme des zones erronées.

2.3.1.14 Mesure de Straster

Straster et Gerbrands ont modifié le critère de Pratt comme suit :

$$STR(I_F, I_{ref}) = \begin{cases} \frac{1}{C_{I_F/ref}} \sum_{k=1}^{C_{I_F/ref}} \frac{1}{1 + \alpha \left(d(I_F^{cont}(k), I_{ref}^{cont}) \right)^2} & \text{si } C_{I_F/ref} > 0 \\ 1 & \text{si } C_{I_F/ref} = 0 \end{cases}$$

Où :

$$C_{I_F/ref} = card(I_F^{cont}) - card(I_F^{cont} \cap I_{ref}^{cont})$$

2.3.1.15 Mesure de Peli et Malah

Dans la même catégorie de critères, nous pouvons aussi trouver Peli et Malah qui utilisent deux critères statistiques, la moyenne :

$$PEL1(I_F, I_{ref}) = \frac{1}{card(I_F)} \sum_{k=1}^{card(I_F)} d(I_F^{cont}(k), I_{ref}^{cont})$$

Et la variance de l’erreur de détection :

$$PEL2(I_F, I_{ref}) = \frac{1}{card(I_F)} \sum_{k=1}^{card(I_F)} \left(d(I_F^{cont}(k), I_{ref}^{cont}) \right)^2$$

2.3.1.16 Critère d’Odet

Odet propose une mesure de divergence qui permet d’évaluer différents niveaux d’erreur de résultats de segmentation binaires : évaluation de détection de frontières avec un faible écart par rapport à la VT et erreur moyenne.

Quatre mesures de divergence ont été définies comme suit :

$$ODI_n = \frac{1}{N_o} \sum_{k=1}^{N_o} \left(\frac{d_o(k)}{d_{TH}} \right)^n$$

$$ODP_n = \frac{1}{N_o} \sum_{k=1}^{N_o} \left(\frac{d_o(k)}{d_{TH}} \right)^n * \text{sign}(d_o(k))$$

$$UDI_n = \frac{1}{N_u} \sum_{k=1}^{N_u} \left(\frac{d_u(k)}{d_{TH}} \right)^n$$

$$UDP_n = \frac{1}{N_u} \sum_{k=1}^{N_u} \left(\frac{d_u(k)}{d_{TH}} \right)^n * \text{sign}(d_u(k))$$

Où :

- N_o correspond à : $\text{card}(I_F^{cont}) - \text{card}(I_F^{cont} \cap I_{ref}^{cont})$,
- N_u correspond à : $\text{card}(I_{ref}^{cont}) - \text{card}(I_F^{cont} \cap I_{ref}^{cont})$,
- $d_o(k)$ correspond à la distance entre le pixel $I_F^{cont}(k)$ et le pixel le plus proche de I_{ref}^{cont} n'appartenant pas à I_F^{cont} ,
- $d_u(k)$ correspond à la distance entre le pixel $I_{ref}^{cont}(k)$ n'appartenant pas à $I_F^{cont}(k)$ et le pixel le plus proche de $I_F^{cont}(k)$,
- d_{TH} correspond à la distance de seuil de détection d'un pixel de la frontière,
- n correspond à un facteur d'échelle,
- $\text{sign}(x)$ correspond à la fonction retournant le signe de x , ce qui permet de savoir si l'on se trouve à gauche ou à droite du contour.

2.3.1.17 Critère de Correia

Dans son travail sur l'évaluation de qualité d'un résultat de segmentation, Correia utilise des critères spatio-temporels sur un résultat de segmentation dans une vidéo. Les critères présentés correspondent à l'étude des images de manière spatiale. Le principe de base prend en compte le fait qu'une bonne segmentation doit avoir des frontières très similaires à celles de la référence. Quand une superposition de formes parfaites n'est pas atteinte, un ensemble de caractéristiques de l'objet peut être vérifié :

- *La fidélité de forme* : le nombre de pixels mal classés ainsi que leur distance à la frontière référence de l'objet sont pris en compte pour calculer la fidélité de la forme de l'objet,
- *La similarité géométrique* : les similarités des caractéristiques géométriques relatives à la taille, la position et une combinaison d'élongation et de compactage entre la référence R et l'objet estimé E sont évaluées ,
- *La similarité du contenu des frontières* : la similarité de la complexité de l'aire spatiale de l'objet estimé avec la référence peut être mesurée par le contenu de sa frontière,
- *La similarité statistique des données* : la similarité de quelques propriétés statistiques de l'objet estimées avec la référence peut aussi être évaluée.

Des poids ont été assignés aux différentes classes en tenant compte à la fois de leur force à capter l'attention humaine et de leur capacité à rassembler des résultats d'évaluation produits par des observateurs humains. La fidélité de forme est souvent affectée du poids le plus important car cette caractéristique est l'indication principale d'erreur avec la référence. L'évaluation spatiale proposée par Correia est donnée par le critère COR . Ce critère semble plus efficace lorsqu'un objet est prédominant dans la scène.

$$COR = \alpha * \text{forme} + \beta * \text{geom} + \gamma * \text{frontiere} + \delta \text{statistic}$$

2.3.1.18 Critère de Nguyen et Ziou

Ce critère d'évaluation présenté par Nguyen et Ziou consiste à utiliser un détecteur de frontières plusieurs fois sur une image synthétique dont on fait varier les caractéristiques et les paramètres du détecteur. L'influence des paramètres sur le détecteur de frontières est ainsi déterminée. La performance du détecteur est déterminée en comparant les frontières obtenues avec les frontières théoriques. Pour ce faire, quatre classes de pixels sont utilisées : idéal, ambigu, non ambigu ou faux. Une distance est alors définie correspondant à la distance maximale acceptée pour conclure qu'un pixel appartient à la frontière. Les pixels de frontières n'appartenant pas à la zone délimitée par cette zone sont ambigus.

La performance d'un détecteur de frontières est alors définie par six types d'erreurs : les erreurs d'omission, de localisation, de réponses multiples, de sensibilité, de suppression et celles d'orientation. Un bon détecteur de frontières doit alors minimiser toutes ces erreurs. Les erreurs de suppression et d'orientation ne concernant que les détecteurs à base de gradients. L'espace des paramètres de chaque méthode de segmentation est parcouru et huit mesures de performances sont alors acquises lors de chaque segmentation : l'opérateur de différenciation, le filtre, l'échelle, le type de frontière, la précision, le rapport signal sur bruit, le 'subpixel' et la distance maximale de détection d'un pixel comme appartenant à la frontière.

Ce critère permet de sélectionner un type de segmentation pour une application donnée avec des besoins particuliers. Cependant, des améliorations peuvent être apportées comme la définition d'un meilleur procédé de synthèse de résultats expérimentaux.

2.3.1.19 Critère de Lopez

La technique présentée par Lopez a pour objectif d'évaluer des résultats de segmentation avec une faible erreur de détection par rapport à la frontière théorique. Il prend en compte une évaluation visuelle subjective utilisant le critère de voisinage et d'erreur d'interaction. Elle combine la divergence objective pixel par pixel entre les frontières obtenues et celles théoriques avec une évaluation effectuée par des observateurs humains. Ces mesures appartiennent à une classe qui peut être appelée le 'modèle de faible erreur' de qualité. Elles ne sont pas conçues pour traiter des erreurs excessives ou aberrantes. Cette mesure est caractérisée par différentes caractéristiques de la segmentation : la divergence, la justesse empirique, le voisinage, les erreurs d'interprétation, le modèle de faible erreur et la mesure de qualité.

La mesure de qualité est définie comme étant la somme de toutes les valeurs (positives) assignées aux erreurs.

$$LOP(I_F, I_{ref}) = K \left(w \sum_{(i,j) \in I_{F/ref}^{cont}} \frac{1 + bn_b(i,j)}{1 + pn_e(i,j) + i_{bh}n'_h(i,j)} + \sum_{(i,j) \in I_{F/ref}^{cont}} \frac{1 + hn_h(i,j)}{1 + c_{Euler}i_{hb}n'_b(i,j)} \right)$$

Où :

- $n_b(i,j)$ est le nombre de pixels de $I_{F/ref}^{cont}$ dans le voisinage 8-connexe du pixel (i,j) ,
- $n_h(i,j)$ est le nombre de pixels de $I_{ref/F}^{cont}$ dans le voisinage 8-connexe du pixel (i,j) ,
- $n'_b(i,j)$ est le nombre de pixels de $I_{F/ref}^{cont}$ en contact avec le pixel (i,j) ,
- $n'_h(i,j)$ est le nombre de pixels de $I_{ref/F}^{cont}$ en contact avec le pixel (i,j) ,
- $n_e(i,j)$ est le nombre de pixels de frontière réels dans le voisinage 8-connexe du pixel (i,j) ,
- $K, w, b, h, p, c_{Euler}, i_{bh}, i_{hb}$: correspondent à des facteurs de normalisation et d'atténuation.

Plus le critère est proche de zéro, plus la segmentation est supposée être bonne. L'expression *LOP* contient un ensemble de coefficients qui sont déterminés au préalable sur des essais. Cependant, ces coefficients peuvent être modifiés pour diverses raisons telles qu'un besoin spécifique de l'application ou des observateurs différents. Les résultats de segmentation sont ensuite ordonnés. Ensuite cet ordre et l'ordre obtenu grâce au critère d'évaluation de qualité sont comparés.

L'expression mathématique de ce critère a été obtenue de manière simple et intuitive, et possède une très bonne efficacité de calcul. Cette mesure est très souple car elle peut être adaptée à des critères plus spécifiques d'appréciation visuelle grâce à ses sept coefficients mais un entraînement préalable est nécessaire.

2.3.2 Critères non supervisés

Dans ce paragraphe, nous présentons des critères d'évaluation non supervisée de résultats de segmentation d'images représentés par différentes frontières détectées. Du fait de la complexité de cette tâche d'évaluation, peu de critères sont disponibles dans la.

2.3.2.1 Critères de Levine et Nazif

Ces critères permettent d'évaluer deux types de frontières : les frontières séparant deux objets de la scène et les lignes qui traversent un objet, sans qu'il y ait de différence de couleur ou de texture entre les régions autour de cette ligne. Le premier type de frontière est évalué par le contraste entre les régions, alors que le second est évalué par le gradient moyen le long de la ligne. Dans le cas d'une image couleur, les calculs sont effectués séparément sur chaque canal et fournissent un vecteur de mesures.

Nous définissons I_F comme une cartographie de frontières d'une image I composée de Nl lignes l_i , $i = 1..Nl$. Nous considérons a comme une caractéristique ou un attribut. On calcule la moyenne de cet attribut sur une région : $\bar{a}(R_k)$. Les différents critères de Levine et Nazif sont alors présentés ci-dessous :

- le contraste de part et d'autre d'une ligne l_i est défini comme suit :

$$NAZ1(l_i) = \frac{|C_g(l_i) - C_d(l_i)|}{C_g(l_i) + C_d(l_i)}$$

avec :

$$C_g(l_i) = \sum_{R_k \in W_g(l_i)} \text{card}(l_i \cap R_k) \bar{a}(R_k)$$

$$C_d(l_i) = \sum_{R_k \in W_d(l_i)} \text{card}(l_i \cap R_k) \bar{a}(R_k)$$

$C_g(l_i)$ correspond à la somme des moyennes de l'attribut a sur les régions voisines de l_i situées à gauche de l_i ($R_k \in W_g(l_i)$) et pondérées par la longueur de la frontière commune $\text{card}(l_i \cap R_k)$.

$C_d(l_i)$ correspond à la somme des moyennes de l'attribut a sur les régions voisines de l_i situées à droite de l_i ($R_k \in W_d(l_i)$) et pondérées par la longueur de la frontière commune $\text{card}(l_i \cap R_k)$.

L'attribut a peut être tout simplement le niveau de gris des pixels ou bien encore un calcul d'attribut de texture.

- Le gradient moyen le long d'une ligne l_i est défini comme suit :

$$NAZ2(l_i) = \frac{\bar{G}}{\max_{x \in (R_k \cap W(l_i))} (a(x)) - \min_{x \in (R_k \cap W(l_i))} (a(x))}$$

Où \bar{G} correspond au gradient moyen de l'attribut a calculé le long des pixels de la ligne l_i et le dénominateur est la différence entre les valeurs maximales et minimales de l'attribut (couleur ou intensité) de l'ensemble des pixels des régions bordant l_i .

- Un critère prenant en compte les deux types de frontières peut être défini comme suit : D'abord on donne l'expression de $h(l_i)$.

$$h(l_i) = \begin{cases} NAZ2(l_i) & \text{si } NAZ2(l_i) > 3 \times NAZ1(l_i) \text{ et } NAZ1(l_i) < \varepsilon \\ NAZ1(l_i) & \text{sinon} \end{cases}$$

Où ε correspond à une constante arbitraire proche de 0. Il en résulte le critère suivant :

$$NAZ3(I_F) = \frac{\sum_{l_i \in I_F} w_i \times h(l_i)}{2 \times \sum_{l_i \in I_F} w_i}$$

Où w_i correspond à un poids représentant la contribution de la ligne l_i . Ce poids peut être son nombre de pixels.

- Un indice de connexité des frontières sert à mesurer les frontières manquantes. Une frontière non fermée possède une ou deux extrémités. Le critère défini comme suit permet de mesurer cette connexité des frontières. Cet indice est normalisé.

$$NAZ4(I_F) = \frac{\sum_{l_i \in I_F} \text{card}(l_i) \times t(l_i)}{2 \times \sum_{l_i \in I_F} \text{card}(l_i)}$$

Où $t(l_i)$ est le nombre d'extrémités de la ligne l_i de la frontière I_F (qui vaut 0, 1 ou 2).

2.3.2.2 Critère de Han et Kim

Ce critère est un facteur flou proposé par Han et Kim et défini comme étant une distance d'ambiguïté. Il peut être utilisé dans la détermination de la justesse de détection des frontières. Trois mesures sont utilisées pour calculer l'ambiguïté : l'existence, la localisation et la disposition. L'ambiguïté d'existence et l'ambiguïté de localisation sont dérivées d'une généralisation de la représentation des frontières en utilisant des ensembles flous. L'ambiguïté de disposition est calculée par les connectivités des frontières.

2.3.2.3 Critère de Kitchen et Rosenfeld

Kitchen et Rosenfeld ont proposé un critère d'évaluation des cartes de frontières fondée sur la cohérence locale des frontières. Cette cohérence est évaluée sur la base de deux critères de caractérisation des frontières : la continuité et la minceur. Les frontières sont supposées être générées par un détecteur de frontières de type gradient, suivi par un seuillage. La direction du gradient est supposée connue en chaque pixel.

2.3.2.4 Critère de Gelfand

Une autre mesure plus complexe que le critère précédent a été proposée par Gelfand, Tan et Delp. La qualité de la carte des frontières est caractérisée par un critère correspondant à une fonction coût $C(I_F)$, exprimée comme une somme des coûts locaux $C(I_F)(i, j)$ pour tous les pixels de l'image.

$$C(I_F) = \sum_{(i,j) \in I_F} C(I_F)(i, j)$$

Chaque coût local au pixel (i, j) est une somme pondérée de cinq facteurs coûts locaux : dissimilarité (C_d), courbure (C_c), nombre de pixels frontière (C_e), fragmentation (C_f) et minceur (C_t).

$$C(I_F)(i, j) = \sum_{k \in \{d, c, e, f, t\}} w_k C_k(I_F)(i, j)$$

Où w_k est un poids fixé arbitrairement.

La fonction d'évaluation présentée peut être caractérisée comme heuristique. En effet, cette fonction n'est pas fondée sur un modèle mathématique précis, mais essaie plutôt de combiner d'une façon 'raisonnable' des critères liés à l'image et à la structure locale des frontières.

2.3.2.5 L'énergie d'une courbe

Il existe des cas où on ne s'intéresse pas à un résultat de segmentation complet de l'image, mais plutôt à la détection de la frontière d'un certain objet dans l'image ou d'une partie d'un objet. Pour cela, on utilise souvent des modèles variationnels qui sont fondés sur la caractérisation d'une structure de la frontière, à savoir un arc ou une courbe. Le modèle des contours actifs, ou snakes, est un des plus connus permettant de modéliser une frontière comme une courbe fermée ou non. Il existe deux grands types de modèles de contours actifs : les modèles continus et les modèles discrets. Dans un modèle continu, le contour actif est représenté par une courbe paramétrée C :

$$C = \{v(s, t) = (x(s, t), y(s, t)), s \in [a, b], t \in [0, T]\}$$

Où a et b sont les extrémités de la frontière, s est l'abscisse curviligne le long de la frontière et t est une variable temporelle. Chaque courbe C est caractérisée par une énergie, intégrant les caractéristiques intrinsèques de cette courbe, les caractéristiques de l'image au voisinage de la courbe et l'interaction entre la courbe et l'image :

$$E(C) = E_{interne}(C) + E_{externe}(C) + E_{image}(C)$$

Où :

- L'énergie interne $E_{interne}(C)$ est un terme de régularisation au sens des problèmes mal posés. Cette énergie devrait assurer à la frontière une certaine continuité (étendue aussi aux dérivées) permettant ainsi d'atténuer les effets du bruit.
- L'énergie externe $E_{externe}(C)$ sert à introduire des informations de haut niveau par l'utilisateur, si elles existent. Ce terme se traduit par la présence de forces de répulsions en certains pixels de la courbe ou des forces d'élasticité entre deux pixels de la courbe. Dans le cas où il n'existe pas d'information a priori sur la courbe, cette énergie est généralement égale à 0.
- L'énergie image $E_{image}(C)$ est le terme d'interaction entre la courbe et l'image. Ce terme dépend des caractéristiques de l'image que l'on cherche à mettre en évidence par la frontière.

Une faible valeur de l'énergie $E(C)$ correspond donc à une courbe C qui est lisse, qui cohere bien avec la forme de l'objet recherché et qui respecte (s'il y a lieu) les contraintes de haut niveau. Cette énergie peut donc être utilisée comme une fonction d'évaluation de la qualité de la frontière. L'optimisation de ce critère est utilisée pour déterminer la frontière optimale d'objets. L'avantage principal de ce type de critère d'évaluation réside dans son utilisation à évaluer les frontières d'un objet particulier d'une image. Un autre avantage concerne le fait qu'un tel critère va pouvoir prendre en compte le contour d'un objet sans prendre en compte ce qu'il y a à l'intérieur. Un inconvénient majeur réside dans le fait que l'on doit connaître approximativement la position de l'objet à évaluer pour pouvoir initialiser la courbe de départ permettant de calculer l'énergie et pour avoir convergence, ce qui n'est pas toujours possible.

2.4 Évaluation dédiée 'régions – contours'

Nous présentons ici d'autres critères d'évaluation de résultats de segmentation plus généraux, ne faisant pas distinction entre segmentation en régions ou détection de frontières. Ils peuvent, en effet, être aussi bien utilisés pour évaluer les résultats de la segmentation de manière supervisée que de manière non supervisée. Seulement le problème majeur pour ces critères est de savoir quoi évaluer dans un cas particulier pour obtenir le résultat souhaité. En somme, ce genre de critères peut être efficace pour des évaluations très particulières, mais ne permet pas d'avoir un critère général utilisable sur tous les résultats de segmentation.

2.4.1 Critère du champ de markov

Dans le cadre de son application à la segmentation, la théorie des champs de Markov fournit un cadre mathématique très puissant permettant de caractériser, par l'intermédiaire d'une fonctionnelle (une énergie), la qualité d'une segmentation. Le résultat de la segmentation est représenté par un champ markovien, pouvant être soit une carte binaire de frontières, soit une carte étiquetée des régions. L'énergie associée au champ résultat correspond généralement à une probabilité a posteriori de réalisation de ce champ. Une bonne qualité de la segmentation correspond à une probabilité élevée de réalisation du champ.

2.4.2 Critère de Zhang

Zhang et Gerbrands ont développé un nouveau critère d'évaluation à la fois objectif, quantitatif et général. Pour une telle procédure d'évaluation d'un résultat de segmentation, les trois conditions suivantes constituent les hypothèses de base :

- Ce critère doit être général, c'est-à-dire qu'il doit être valable pour toutes les techniques de segmentation. Ainsi, aucun paramètre ou propriété d'algorithme particulier ne doit être utilisé, ce qui évite l'introduction de biais dans certains cas,
- Ce critère doit utiliser des critères quantitatifs et objectifs pour l'évaluation des performances,
- les images utilisées doivent être reproductibles par tous les utilisateurs potentiels d'un tel critère.

Trois étapes sont alors nécessaires pour l'évaluation d'un résultat de segmentation :

1. la première consiste à générer des images de test synthétiques,
2. la deuxième est une procédure d'analyse se déroulant comme suit :
 - l'algorithme de segmentation est appliqué à l'image,
 - les caractéristiques désirées des objets présents dans l'image sont mesurées.
3. enfin, la troisième correspond à l'évaluation des performances de l'algorithme.

2.5 Conclusion

Ce présent chapitre rassemble l'état de l'art établi concernant les différents critères d'évaluation, dits aussi indicateurs de performance, qui puissent exister dans la littérature. Nous avons pu constater que les critères d'évaluation supervisés consistent pour la plupart en une mesure de distance entre une référence et un résultat de segmentation, tandis qu'une évaluation non supervisée consiste en général à calculer des statistiques sur les éléments d'un résultat de segmentation. Les critères d'évaluation supervisée semblent donner des résultats corrects, mais sont très contraignants en terme de moyens à fournir pour mener l'évaluation. Les critères d'évaluation non supervisée semblent plus intéressants car ils sont moins contraignants en terme d'utilisation.

Dans ce mémoire nous avons classifié ces différents critères de manière assez explicite dans le but de faciliter la tâche à l'opérateur qui est dans le besoin d'évaluer le résultat d'une éventuelle segmentation. C'est notre cas puisque nous nous sommes basées sur cette classification pour faire le choix des critères que nous avons utilisés dans notre approche pour concevoir le système de segmentation automatique. C'est ce que nous allons détailler dans le prochain chapitre.

Chapitre 3

Implémentation de La Segmentation Automatique

*"Le savant n'est pas l'homme qui fournit
les vraies réponses; c'est celui qui pose
les vraies questions."*

Claude Lévi-Strauss

3.1 Introduction

Comme nous l'avons déjà évoqué, l'étape de segmentation est assez importante dans la chaîne du traitement d'images. C'est la raison pour laquelle nous cherchons à optimiser le traitement c'est-à-dire la segmentation afin de performer le diagnostic qui découle du résultat de la segmentation. De là l'évaluation du résultat de la segmentation est devenue une étape aussi importante dans le déroulement du traitement d'images. Dans ce chapitre, nous présentons notre travail de recherche qui consiste à établir un système automatique de segmentation des images cytologiques basé sur l'évaluation du résultat de la segmentation. Notre persévérance a abouti à proposer deux systèmes de segmentation automatique que nous allons détailler dans le paragraphe (§ 3.5). Le prochain paragraphe résume notre démarche et façon de concevoir ces deux systèmes. Le paragraphe (§3.3) présente la méthode de segmentation que nous avons utilisée pour notre application. Quant au paragraphe (§3.4), il présente les critères d'évaluation que nous avons utilisés et récapitule leurs définitions.

3.2 Étude de cas

Nous rappelons que le but de notre étude est de donner une bonne segmentation des images cytologiques. Cependant une segmentation de ce type d'images est dite bonne si elle arrive à distinguer les cellules du cytoplasme et aussi de leurs noyaux. Au départ nous avons pensé à fournir une qualification et une entière évaluation du résultat de la segmentation et dire qu'elle est bonne ou mauvaise afin de l'accepter ou de la refuser. Par la suite, notre réflexion a été conduite à améliorer le résultat de la segmentation en mettant en place un système automatique ou semi-automatique selon la possibilité pour régler efficacement et en temps réel les défaillances de la segmentation.

Pour cela, nous proposons deux approches. La première approche consiste à réaliser un système automatique qui effectue plusieurs segmentations de l'image initiale pour de différentes valeurs des paramètres d'action. Ces paramètres d'action sont par définitions les paramètres qui

agissent sur la méthode de segmentation utilisée. Et depuis les différentes images résultats de la segmentation, le système automatique en choisit la meilleure et la fournit en sortie.

Comme deuxième approche, nos efforts ont abouti à mettre en œuvre un système automatique qui a pour but d'améliorer le résultat de la segmentation en agissant sur les paramètres d'action de la méthode de segmentation utilisée et cela selon les indicateurs de performance qui ne sont autres que des critères d'évaluation et qui servent bien sûr à l'évaluer. A partir de ces critères le système passe par un contrôleur basé sur des règles floues pour donner en sortie de ce contrôleur de nouvelles valeurs des paramètres d'action de la méthode de segmentation utilisée. Le système continue la correction de la segmentation jusqu'à obtention de la meilleure segmentation. Cette décision est prise suivant l'indication des critères de performance.

3.3 Étapes de la procédure de la segmentation

Au départ et afin d'effectuer un prétraitement de l'image originale nous appliquons un filtre personnalisé avec le masque suivant :

$$h = \frac{1}{10} \begin{bmatrix} 1 & 2 & 1 \\ 1 & 0 & 1 \\ 1 & 2 & 1 \end{bmatrix}$$

Il est à mentionner que notre choix a été porté après plusieurs essais avec de différents masques de filtrage. Ceci dit que notre choix a été purement expérimental, du moins en ce qui concerne les images cytologiques.

Par la suite nous procédons à une étape de segmentation. Au départ nous avons utilisé l'algorithme de classification le Fuzzy-C-Means (*FCM*) dit aussi le *C-Moyennes-Floues* [27]. Mais le résultat a donné parfois trop de classes (Fig 3.1) dont certaines peuvent bien être fusionnées. Pour la fusion des classes nous avons pensé à appliquer la méthode d'agglomération (algorithme de compactness et d'isolation) proposé par Lambert et Grecu [28,29]. Mais le résultat de cette approche pour notre application (Fig 3.2) n'a pas forcément donné la meilleure fusion des classes de l'image classifiée. Par la suite nous avons eu l'idée de faire fusionner les classes qui se rapprochent dans leurs attributs couleurs moyennes, et ceci a donné de meilleurs résultats (Fig 3.3).

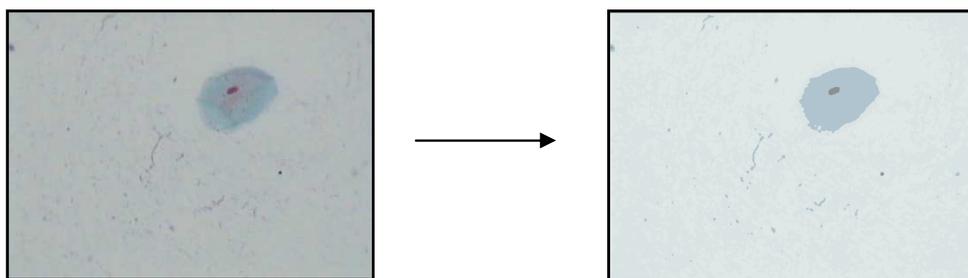


Fig 3.1. Exemple du résultat de la classification par *FCM*.

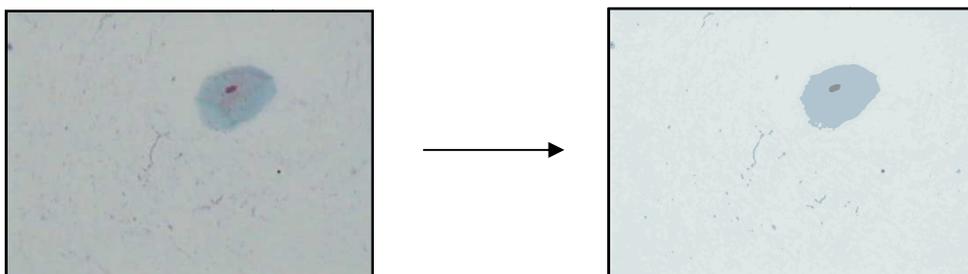


Fig 3.2. Fusion des classes selon le processus d'agglomération de Lambert-Grecu.

Après la classification nous appliquons l'algorithme d'étiquetage en régions connexes afin de donner des étiquettes ou "labels" aux différentes régions et de là, séparer les régions appartenant à la même classe (Fig 3.4). Après avoir effectué un étiquetage des différentes régions nous procédons à un calcul de leurs tailles, afin d'éliminer les régions de petites tailles. Il est à noter que la définition d'une région de taille 'petite' doit être choisie avec soin, vu qu'un choix plus ou moins grand peut éliminer la région du noyau, ce qui ne doit surtout pas être fait. En même temps, nous avons procédé à l'élimination des effets de bord éventuellement présents dans l'image segmentée. Le résultat de cette étape est illustré sur la figure (Fig 3.5).

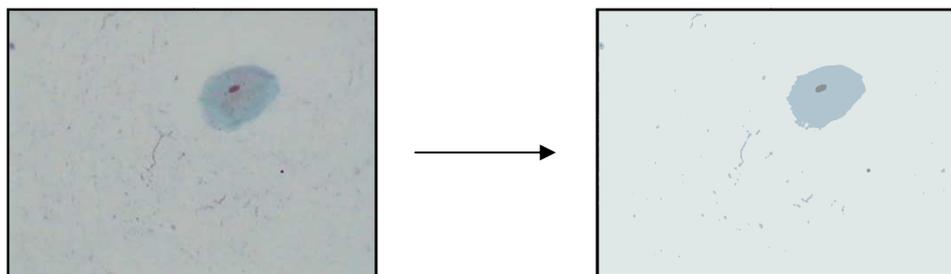


Fig 3.3. Fusion des classes selon l'attribut couleur.

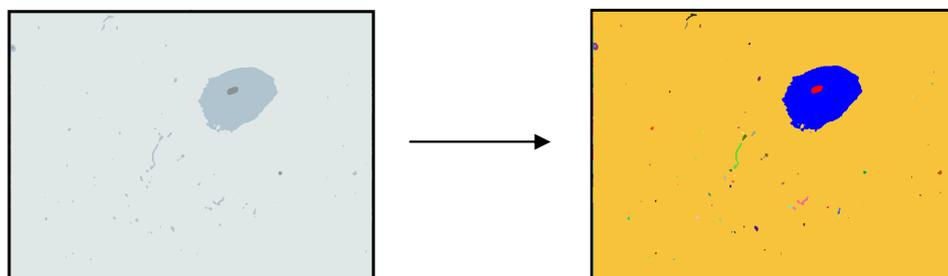


Fig 3.4. Étiquetage de l'image classifiée.

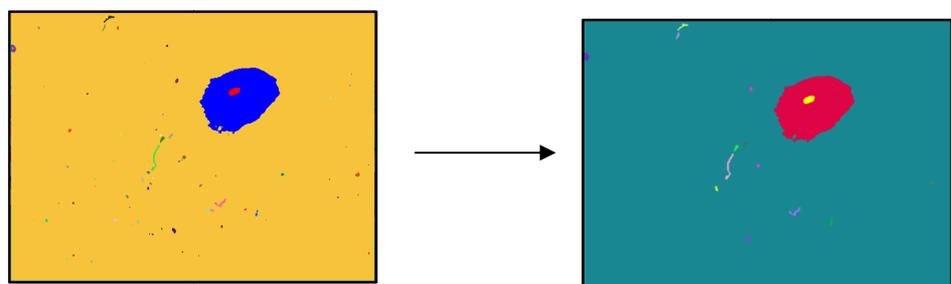


Fig 3.5. Suppression des petites régions et des effets de bord dans l'image segmentée.

A partir de l'image segmentée en régions nous effectuons une étape de détection de contours (Fig 3.6) afin de pouvoir l'utiliser pour le calcul des critères d'évaluation de la segmentation contours. Pour récapituler nous pouvons dire que, l'étape de la segmentation régions comporte les quatre phases suivantes :

- Classification par *FCM*,
- Fusion des classes,
- Étiquetage,
- Suppression des petites régions et les effets de bord.

La figure (Fig 3.7) résume les différentes étapes de la segmentation utilisée dans notre application. Toutes ces étapes vont être expliquées avec plus de détails dans la suite de ce paragraphe.

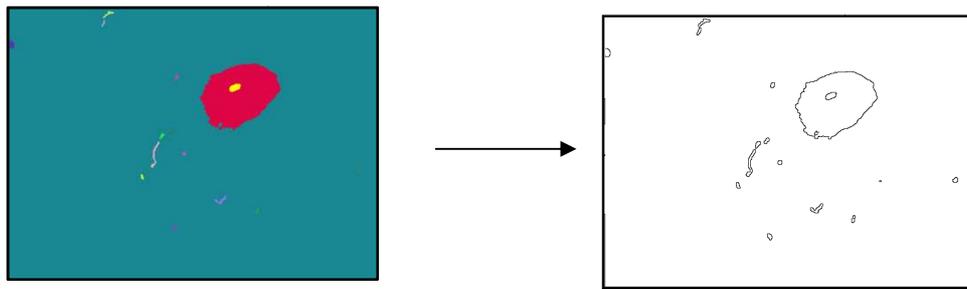


Fig 3.6. Détection de contours.

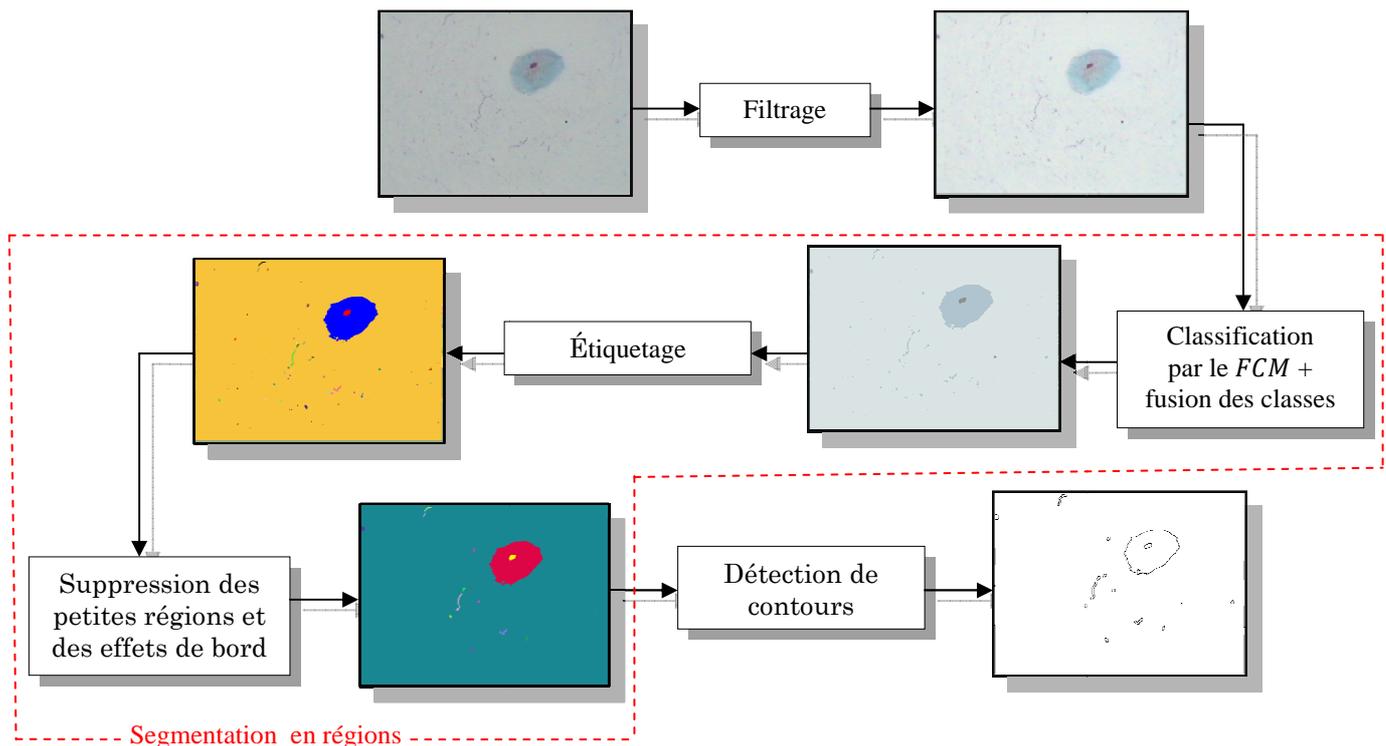


Fig 3.7. Étapes de la procédure de la segmentation utilisée.

Dans les deux paragraphes qui suivent, nous présentons en détail la méthode de classification par *FCM* ainsi que l'opération d'étiquetage

3.3.1 Classification par l'algorithme du Fuzzy-C-Means (*FCM*)

L'algorithme du Fuzzy-C-Means ou encore des *C-Moyennes-Floues* est une technique de classification, qui a été introduite par J. C. Bezdek [18] et qui a été souvent utilisée dans de différents domaines.

Comme dans [27], à notre tour nous avons adapté cet algorithme à la classification des images, plus précisément les images couleur. Notre démarche vise à assigner à chaque pixel de l'image un degré d'appartenance flou (compris entre 0 et 1) pour chacune des classes de centre de gravité C_i . Le calcul du degré d'appartenance se base sur la caractéristique couleur des différents pixels.

Après avoir effectué une première classification initiale, l'algorithme du *FCM* adapté à l'image couleur cherche à classer au mieux les pixels de l'image aux différentes classes et cela en

se basant sur la logique floue. Par définition, le *FCM* est considéré comme étant un algorithme de classification floue non-supervisée. Issu de l'algorithme des *C-moyennes* (*C-means*), il introduit la notion d'ensemble flou dans la définition des classes : chaque point de l'ensemble des données appartient à chacune des classes avec un certain degré, et toutes les classes sont caractérisées par leur centre de gravité. Comme les autres algorithmes de classification non supervisée, il utilise un critère de minimisation des distances intra-classes et de maximisation des distances inter-classe, mais il donne un certain degré d'appartenance à chaque classe pour chaque pixel. Cet algorithme nécessite la connaissance préalable du nombre de classes et génère les classes par un processus itératif en minimisant une fonction objectif. Ainsi, il permet d'obtenir une partition floue de l'image en donnant à chaque pixel un degré d'appartenance (compris entre 0 et 1) à une classe donnée. Ce degré d'appartenance est calculé à partir d'une formule qui utilise l'indice flou m . La classe à laquelle est associé un pixel est celle dont le degré d'appartenance sera le plus élevé. Les principales étapes de l'algorithme Fuzzy-C-Means sont :

1. La fixation arbitraire d'une matrice d'appartenance des pixels de l'image, de telle façon que :

$$\sum_{i=1}^c u_{ij} = 1, \quad \forall j = 1, \dots, n$$

2. Le calcul des centroïdes des classes selon la formule suivante :

$$c_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{j=1}^n u_{ij}^m}$$

3. Le réajustement de la matrice d'appartenance suivant la position des centroïdes avec :

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{ij}}{d_{kj}} \right)^{2/(m-1)}}$$

et arrêter l'algorithme si la fonction de dissimilarité est inférieure à un certain seuil prédéfini,

4. Calcul du critère de minimisation qui est la minimisation de la fonction de dissimilarité J , et retour à l'étape 2 s'il y a non convergence du critère.

$$J(U, c_1, c_2, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2$$

Nous précisons que :

- u_{ij} est le degrés d'appartenance du pixel i à la classe j , compris entre 0 et 1,
- c_j est le centroïde de la classe i ,
- d_{ij} est la distance euclidienne entre le $i^{\text{ième}}$ centroïde et le $j^{\text{ième}}$ pixel,
- m est l'exposant flou.

Par conséquent nous avons deux paramètres d'action, le nombre de classes N -classes et l'exposant flou m , qui ont un comportement, par titre de rappel, comme suit :

- Une valeur importante du nombre de classes donne une sur-segmentation, et une valeur plus petite que le nécessaire donne une sous-segmentation.
- Plus m est grand plus on a de régions, et vice versa.

La figure (Fig 3.8) représente quelques résultats donnés par l'algorithme du Fuzzy-C-Means en fixant m à la valeur 3.4 et faisant varier le nombre de classes de : $\{2, 3, 7\}$ respectivement de gauche à droite.

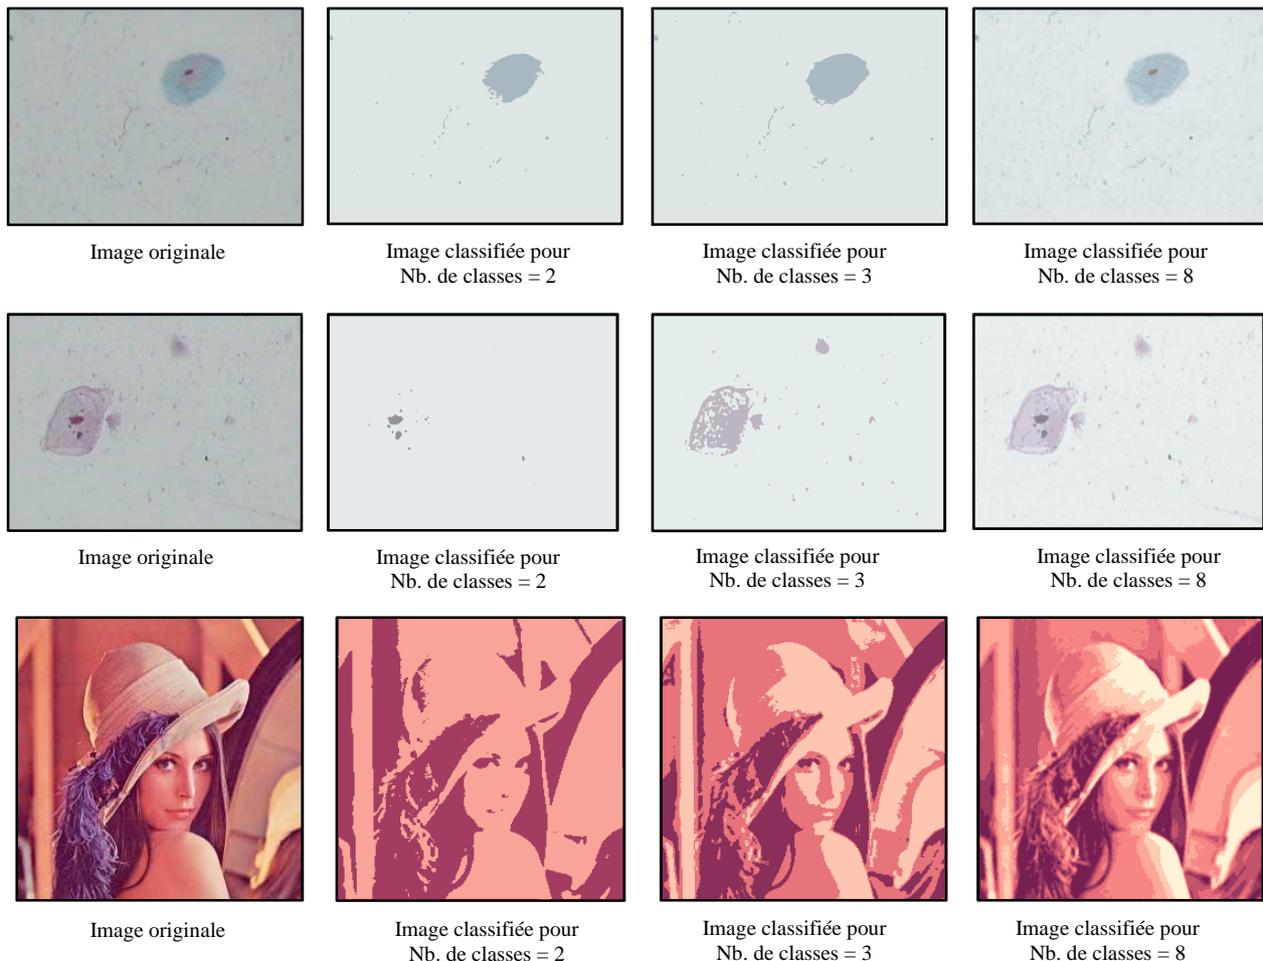


Fig 3.8. L'influence du paramètre "Nombre de classes" sur la classification par L'algorithme Fuzzy-C-Means, pour $m = 1.5$.

Tandis que la figure (Fig 3.9) illustre quelques résultats donnés par le *FCM* en fixant le nombre de classes à 4 classes pendant que m prend les valeurs : $\{2, 4.7, 7\}$ respectivement de gauche à droite. Ces deux figures montrent la variation du résultat de la segmentation en fonction des paramètres d'action considérés.

3.3.2 Étiquetage

Le résultat de la segmentation en utilisant l'algorithme du Fuzzy-C-Means est une classification des différentes régions de l'image, ce qui peut nous donner deux régions non connexes qui sont libellées de la même classe (ou la même étiquette). Ceci peut prêter à confusion si par exemple dans l'image originale nous avons deux cellules à détecter alors que le résultat de la classification détermine une seule cellule. C'est pour cette raison que nous avons procédé à une étape d'étiquetage afin de différencier tous les objets existant dans l'image pouvant avoir les mêmes propriétés.

Pour cela, nous avons utilisé la méthode de l'étiquetage en composantes connexes [2], qui fait attribuer à tous les pixels d'une composante connexe une même étiquette (c'est une valeur entière). Chaque composante connexe est alors identifiée par son étiquette.

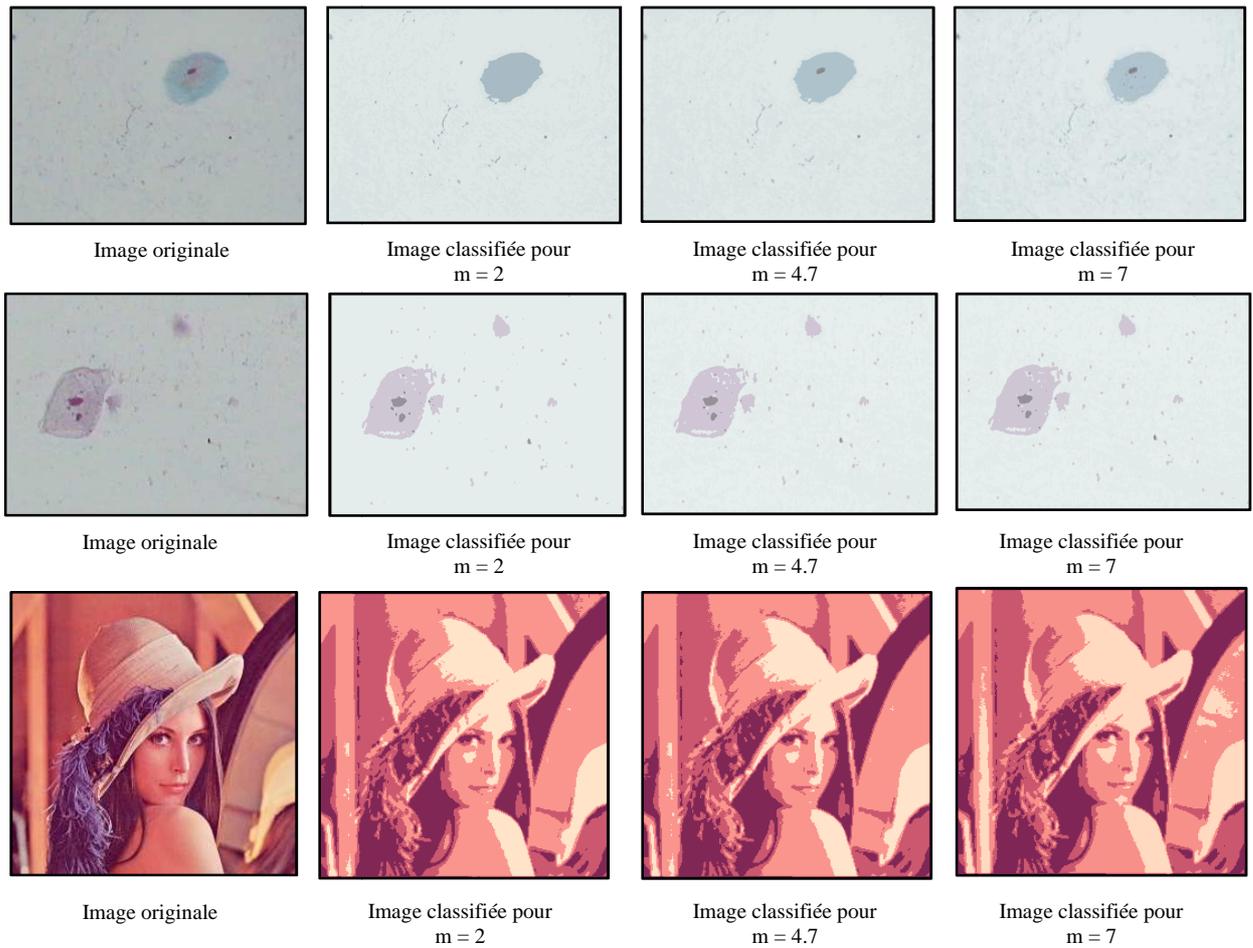


Fig 3.9. L'influence du paramètre "m" sur la classification par L'algorithme Fuzzy-C-Means, pour un Nombre de classes = 6.

L'algorithme d'étiquetage en composantes connexes détecte les adjacences entre pixels et définit l'étiquette du pixel en question en fonction de celles des pixels voisins.

La méthode la plus classique repose sur un balayage séquentiel de l'image. On considère pour chaque pixel x ses voisins déjà traités : deux pixels pour la 4-connexité et quatre pixels pour la 8-connexité. Ces pixels sont nommés les prédécesseurs de x d'un balayage ligne par ligne de l'image (Fig 3.10). Dans notre application nous avons pris les 8-connexité.

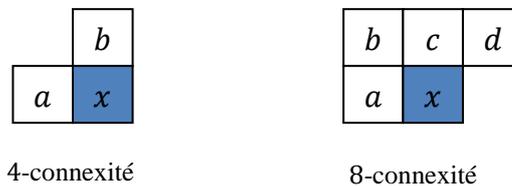


Fig 3.10. Les prédécesseurs du pixel traité dans l'étiquetage en composantes connexes.

Pour réduire à deux le nombre de balayage de l'image, il est nécessaire de construire une table d'équivalence T qui permet de gérer les équivalences d'étiquettes qui apparaissent lors du parcours séquentiel. L'algorithme d'étiquetage en composantes connexes est donné comme suit, où s représente un pixel de coordonnées (i, j) :

```

début
K := 1 ;
pour i := 1 à M faire
  pour i := 1 à N faire
    début
    si (tous les prédécesseurs de A[s] = 0) alors
      E[s] := k ; k := k + 1 ;
    sinon
      si tous les prédécesseurs de A[s] ont la même étiquette alors
        E[s] :=  $\alpha$ 
      sinon
        début
        soit = min{T[E[sp]] | (sp  $\in$  {ensemble des prédécesseurs de s}) et (E[sp]  $\neq$  0)}
        E[s] :=  $\alpha$ 
        pour chaque prédécesseur d'étiquette  $\beta$  telle que T[ $\beta$ ]  $\neq$   $\alpha$  faire
          début
          tant que T[ $\beta$ ]  $\neq$   $\alpha$  faire
            début
            m := T[ $\beta$ ] ; T[ $\beta$ ] :=  $\alpha$  ;  $\beta$  := m ;
            fin
          fin
        fin
      fin
    fin
  fin
fin

```

A la fin du balayage de l'image, on actualise la table T de manière à ce qu'à tout indice corresponde l'étiquette définitive de l'objet, donnée comme suit :

```

pour k := 1 jusqu'à nombre maximum d'étiquettes utilisées faire
  debut
  m := k,
  tant que T[m]  $\neq$  k faire
  m := T[m] ;
  T[k] := m ;
  fin

```

Le second balayage de l'image exploite la table d'équivalence pour affecter à chaque pixel la plus grande étiquette d'une classe d'étiquettes équivalentes.

Nous rappelons qu'après avoir appliqué l'algorithme d'étiquetage en composantes connexes, nous effectuons le calcul des aires des différentes régions afin d'en éliminer les régions de petite taille. Aussi nous corrigerons les effets de bord. Nous précisons aussi qu'à la fin de cette étape, nous avons représenté son résultat par une image couleur en faisant correspondre à chaque étiquette une couleur de représentation.

3.3.3 Segmentation en contours

Pour pouvoir utiliser les critères d'évaluation dédiés pour la segmentation contours, et dans le but de fournir une quantification supplémentaire de la qualité de la segmentation obtenue, nous avons pensé passer à une segmentation contour partant du résultat de la segmentation région.

Comme première démarche, et à partir de l'image segmentée en régions, nous avons tracé les contours des régions qui sont formés des pixels frontières de chaque région. Ce qui a donné des contours d'une épaisseur de deux pixels comme c'est montré sur la figure (Fig 3.11). Pour remédier à cela, et pour chaque paire de régions adjacentes, nous avons procédé de façon à tracer la frontière entre les deux régions par une épaisseur d'un seul pixel. C'est une sorte d'opération d'amincissement de contours. Le résultat de cette correction est présenté sur la figure

(Fig 3.12). Nous remarquons que le résultat est meilleur puisque les contours ont une épaisseur de un pixel.

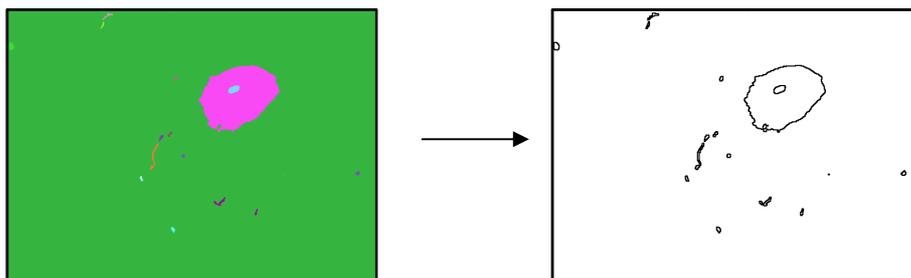


Fig 3.11. Détection de contours selon notre méthode (1^{ière} phase).

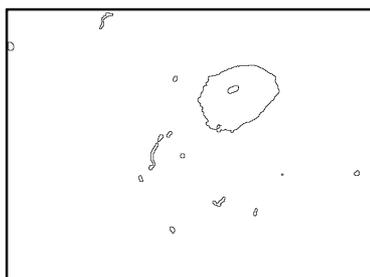


Fig 3.12. Détection de contours selon notre méthode (2^{ème} et dernière phase).

Aussi et comme toute démarche normale, nous avons appliqué les détecteurs de contour classiques afin de les comparer à notre méthode. Il s'agit du détecteur de contour de Canny, de Sobel et de Prewitt [2,16]. Dans notre étude, nous avons apporté une modification à ces détecteurs, en les appliquant sur les trois composantes couleurs de l'espace *RVB* séparément, pour avoir une image contour qui est l'union des trois images contours résultantes. L'application de ces méthodes sur la même image que l'exemple précédent est illustrée sur la figure (Fig 3.13).

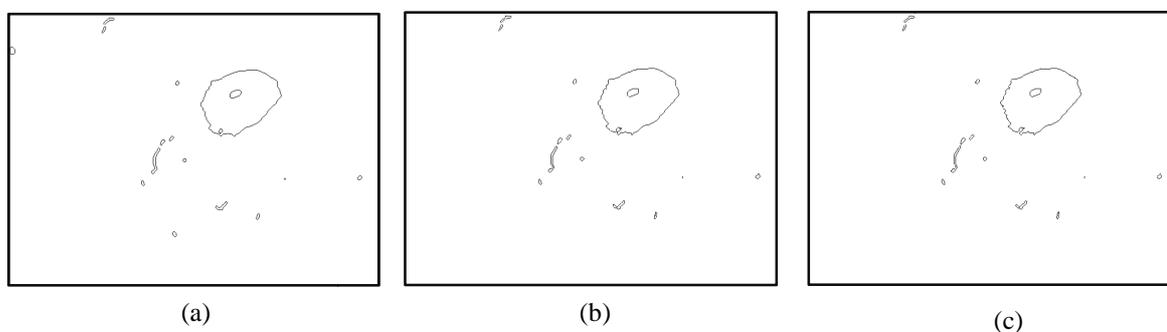


Fig 3.13. Détection de contours selon Canny (a), Sobel (b) et Prewitt (c).

Par la suite, nous avons comparé notre méthode de détection de contours avec les trois autres. Les quatre méthodes donnent des résultats proches et satisfaisants vu que les contours fournis sont fermés et qu'elles ne présentent de sur-détection. Bien que les résultats de ces quatre méthodes sont proches, nous avons préféré utiliser notre méthode, parce que son résultat est plus significatifs et dépend directement du résultat de la segmentation en régions appliquée.

3.4 L'évaluation de la segmentation appliquée

Puisque dans notre travail nous avons appliqué une segmentation en régions et une segmentation en contours et dans le but de qualifier les résultats de segmentations, nous avons fait appel aux critères d'évaluation de la segmentation en régions et ceux d'évaluation de la

segmentation en contours. D'abord nous avons programmé ces critères en guise de les appliquer dans l'espace couleur *RVB*. Puis nous les avons projetés aux différents espaces couleur pour étudier leur fiabilité et leur amélioration apportée à l'échéance. Par conséquent, toute une étude bibliographique des espaces couleur a été faite pour calculer et mettre en œuvre les critères sous les différents espaces couleur. Cependant nous n'avons pas donné suite à cette voix vu que l'interprétation des résultats obtenus était délicate à mettre en place et parfois de comportement variable.

Parmi les critères d'évaluations programmés et présentés dans le chapitre 2, nous avons choisi pour notre application les critères indiqués aux deux prochains paragraphes (§ 3.4.1 et § 3.4.2). Notre choix a été fait après un certain nombre d'essais et selon la signification des différents critères.

Nous rappelons que le principe de l'évaluation supervisée est de qualifier le résultat de la segmentation par rapport à une connaissance a priori qui peut bien être exprimée en une vérité terrain ou des connaissances sur les objets à identifier. Quant à l'évaluation non supervisée, elle consiste à évaluer le résultat de la segmentation sans une connaissance a priori sur l'image désirée. Ce qui a fait que les critères non supervisés se calculent à partir des propres informations contenues dans l'image.

3.4.1 Évaluation du résultat de la segmentation en régions

Les critères que nous utilisons dans notre travail sont les suivants, et dont nous récapitulons leurs différentes définitions :

3.4.1.1 Critères supervisés

- Les deux critères de Yasnoff :

Nous avons considéré deux critères de Yasnoff. Il s'agit de :

$$YAS1(k) = 100 \times \frac{\sum_{i=1}^n (C_{ik} - C_{kk})}{\sum_{i=1}^n C_{ik}}$$

Où : $\sum_{i=1}^n C_{ik}$ représente le nombre total de pixels de la classe k et C_{kk} le nombre de pixels correctement classés dans la classe k .

$$YAS2(k) = 100 \times \frac{[\sum_{i=1}^n C_{ki}] - C_{kk}}{\sum_{j=1}^n \sum_{i=1}^n C_{ij} - \sum_{i=1}^n C_{ik}}$$

Où : $\sum_{i=1}^n C_{ki}$ représente le nombre total de pixels étiquetés avec k ,
Et $(\sum_{j=1}^n \sum_{i=1}^n C_{ij} - \sum_{i=1}^n C_{ik})$ est le nombre de pixels de l'image n'appartenant pas à la classe k .

Une bonne segmentation correspond à une valeur de $YAS1$ proche de 0 et de $YAS2$ proche de 1.

- Le critère de Vinet :

Nous rappelons la définition de la table de superposition:

$$T(I_L, I_{L_{ref}}) = \{card(L_i \cap L_j^{ref}), i = 1..NL, j = 1..NL_{ref}\}$$

Où $card(L_i \cap L_j^{ref})$ est le nombre de pixels étiquetés i dans L en correspondance avec les pixels j dans L^{ref} .

Le mécanisme à appliquer est le suivant :

1. On sélectionne dans le tableau les deux classes qui maximisent $card(L_i \cap L_j^{ref})$,
2. Tous les éléments du tableau qui font partie de la ligne et de la colonne de la cellule sélectionnée sont désélectionnés,
3. Tant qu'il reste des éléments, on retourne à la première étape.

Le critère de Vinet est une mesure de dissimilarité. Il est donné, avec C l'ensemble des cellules sélectionnées, comme suit :

$$VIN(I_L, I_{L_{ref}}) = card(I) - \sum_C card(L_i \cap L_j^{ref})$$

Pour une mauvaise segmentation le critère s'approche de 1, et pour une bonne segmentation il s'éloigne du 1. Donc le critère de Vinet calcule le degré de mauvaise détection. Dans notre travail nous avons calculé le degré de bonne détection. Nous avons pensé donner une nouvelle formulation de ce critère comme suit :

$$VIN(I_L, I_{L_{ref}}) = \sum_C card(L_i \cap L_j^{ref})$$

De là, nous avons constaté que : plus VIN s'approche de 1, meilleure est la segmentation. Pour la suite de ce document, nous avons gardé le nom de critère de Vinet pour cette nouvelle définition.

3.4.1.2 Critères non supervisés

Nous avons adapté certains de ces critères aux images couleur. Les critères de Liu et de Borsotti sont à la base destinés pour les images couleur. Cependant, il existe plusieurs niveaux où nous pourrions introduire la moyenne des trois paramètres, ce qui donne plus de champs à exploiter. Dans notre travail et afin de donner plus de signification aux critères, nous avons préféré remplacer l'intensité "en niveau de gris" (souvent demandée dans la formule de calcul des différents critères) par la moyenne des trois intensités couleur (rouge, vert et bleu). Nous rappelons toujours que ces critères n'utilisent pas une image de référence dans leur calcul.

- L'uniformité de Levine et Nazif :

Une bonne segmentation correspond à une valeur de l'uniformité de Levine proche de 1. Ce critère est donné par l'expression suivante :

$$LEV(I_R) = 1 - \sum_{k=1}^{NR} \frac{\sum_{(i,j) \in R_k} (g_I(i,j) - \sum_{(m,n) \in R_k} g_I(m,n))^2}{card(I) \times \left(\max_{(i,j) \in R_k} (g_I(i,j)) - \min_{(i,j) \in R_k} (g_I(i,j)) \right)^2}$$

où : NR est le nombre de régions,
 A est l'aire de l'image donnée par le nombre de pixels constituant l'image I ,
 R_k indique la région numéro k ,
 $g_I(i,j)$ est l'intensité du pixel de coordonnées (i,j) de l'image résultat I .

Il est à rappeler que dans notre application nous avons substitué l'intensité en niveau de gris par la moyenne des trois intensités couleur.

- L'uniformité de Sahoo :

Plus ce critère est proche de 1, meilleure est la segmentation. Il est donné comme suit :

$$SAH1(I_R) = \sum_{k=1}^{NR} \sum_{(i,j) \in R_k} (g_I(i,j) - \bar{g}_k)^2$$

Où : $\bar{g}_k = \frac{1}{A_k} \sum_{(i,j) \in R_k} g_I(i,j)$ est l'intensité moyenne de la région R_k , où A_k l'aire de la région R_k .

La formule finale est donnée comme étant :

$$SAH2(I_R) = 1 - \frac{SAH1(I_R)}{C}$$

Nous avons pris C égal au produit de la taille de l'image par le nombre de régions.

- **Le contraste de Levine et Nazif :**

Le contraste global de Levine et Nazif est donné par la formule :

$$CLEV3(I_R) = \frac{\sum_{k=1}^{NR} w_{R_k} CLEV2(R_k)}{\sum_{k=1}^{NR} w_{R_k}}$$

Nous avons pris w_{R_k} égal à l'aire de la région R_k . Nous avons aussi :

$$CLEV2 = \sum_{R_k \in W(R_a)} p_{R_a/R_k} CLEV1(R_a, R_k)$$

Où : $p_{R_a/R_k} = \frac{\text{card}(F_{R_a \cap R_k})}{\text{card}(F_{R_a})}$ est le rapport longueur de frontière commune entre R_a et R_k sur le périmètre de la région R_a .

Et : $CLEV1(R_i, R_j) = \frac{|\bar{g}_I(R_i) - \bar{g}_I(R_j)|}{\bar{g}_I(R_i) + \bar{g}_I(R_j)}$ est le contraste entre deux régions adjacentes.

Pour une bonne segmentation le contraste de Levine et Nazif s'approche de 0.

- **Le contraste de Zeboudj :**

Nous présentons :

- Le contraste entre deux pixels x et y de l'image I par :

$$c_I(x, y) = \frac{|g_I(x) - g_I(y)|}{m \sum_{x \in I} g_I(x) - 1}$$

- le contraste intérieur par :

$$C_{int}(R_k) = \frac{1}{A_k} \sum_{x \in R_k} \max\{c_I(x, y), y \in W(x) \cap R_k\}$$

- le contraste extérieur par :

$$C_{ext}(R_k) = \frac{1}{\text{card}(F_{R_k})} \sum_{x \in R_k} \max\{c_I(x, y), y \in W(x), y \notin R_k\}$$

Où F_{R_k} correspond à la frontière de la région R_k .

- le contraste de la région R_k est donné par l'expression suivante avec $(R_k) \in [0,1]$:

$$C(R_k) = \begin{cases} 1 - \frac{C_{int}(R_k)}{C_{ext}(R_k)} & \text{si } 0 < C_{int}(R_k) < C_{ext}(R_k) \\ C_{ext}(R_k) & \text{si } C_{int}(R_k) = 0 \\ 0 & \text{sinon} \end{cases}$$

Le contraste global de Zeboudj de l'image est donné par la formule:

$$CZEB(I_R) = \frac{1}{A} \sum_{k=1}^{NR} A_k \times C(R_k)$$

Une région bien segmentée possède un contraste intérieur faible et un contraste extérieur sur la frontière élevé, donc une valeur de $C(R_k)$ proche de 1. Donc une valeur de $CZEB(I_R)$ proche de 1 correspond à une bonne segmentation.

- **Le critère de Liu :**

L'expression de ce critère est la suivante :

$$LIU(I_R) = \frac{1}{1000 \times \text{card}(I)} \sqrt{NR} \sum_{k=1}^{NR} \frac{e_k^2}{\sqrt{\text{card}(R_k)}}$$

Où e_k correspond à la somme des distances euclidiennes entre les vecteurs couleurs des pixels de la région R_k dans l'image segmentée.

Une bonne segmentation correspond à une valeur de LIU proche de 0.

- **Le critère de Borsotti :**

Ce critère est formulé comme suit:

$$BOR(I_R) = \frac{\sqrt{NR}}{10^4 \times \text{card}(I)} \sum_{k=1}^{NR} \left[\frac{e_k^2}{1 + \log(\text{card}(R_k))} + \left(\frac{\chi(\text{card}(R_k))}{\text{card}(R_k)} \right)^2 \right]$$

Où : $\chi(\text{card}(R_k))$ correspond au nombre de régions ayant une aire égale à $\text{card}(R_k)$.

Une bonne segmentation correspond à une valeur de BOR proche de 0.

3.4.2 Évaluation du résultat de la segmentation en contours

Notons que pour cette classe, nous n'avons pas utilisé les critères de catégorie non supervisés. C'est un choix proprement expérimental.

3.4.1.1 Critères supervisés

- **L'erreur de sur-détection :**

L'erreur de sur-détection est définie comme étant :

$$SUR(I_F, I_{ref}) = \frac{\text{card}(I_F) - \text{card}(I_F \cap I_{ref})}{\text{card}(I_F) - \text{card}(I_{ref})}$$

Si : $SUR = 0$ il n'y a pas de sur-segmentation $I_F \subset I_{ref}$, et si : $SUR = 1$ on a : $I - I_{ref} \subset I_F$.

- **L'erreur de sous-détection** :

L'erreur de sous-détection est donnée par la formule:

$$SOUS(I_F, I_{ref}) = \frac{card(I_{ref/F}^{cont})}{card(I_{ref}^{cont})}$$

Si : $SOUS = 0$ il n'y a pas de sous-segmentation $I_F \subset I_{ref}$, et si : $SOUS = 1$ alors $I_F \cap I_{ref} = \emptyset$.

- **L'erreur de localisation** :

L'erreur de localisation est donnée comme suit:

$$LOC(I_F, I_{ref}) = \frac{card((I_{ref/F}) \cup (I_{F/ref}))}{card(I)}$$

Si : $LOC = 0$, il n'y a pas de mauvaise localisation de frontières $I_F = I_{ref}$, et si : $LOC = 1$ alors $I_F \cap I_{ref} = \emptyset$ et $I_F \cup I_{ref} = I$.

- **La distance L_q** :

Elle est donnée comme étant :

$$L_q(I_1, I_2) = \left(\frac{1}{card(x)} \sum_{(i,j) \in X} (g_{I_1}(i,j) - g_{I_2}(i,j))^q \right)^{\frac{1}{q}}$$

Où $q \in N^*$ (le degré de cette distance). Dans notre application nous avons pris : $q = 3$.

Une petite valeur de cette mesure est la conséquence d'une bonne segmentation.

3.5 Correction et automatisation de la segmentation

Automatiser la segmentation revient à établir un contrôle afin de fournir la meilleure segmentation qui soit d'une manière automatique. Comme nous l'avons déjà précisé nous avons mis en œuvre deux systèmes automatiques de la segmentation des images cytologique.

3.5.1 Première approche

Cette première approche consiste à réaliser un système automatique qui effectue plusieurs segmentations de l'image initiale pour de différentes valeurs des paramètres d'action. Ces paramètres d'action sont par définition les paramètres qui agissent sur la méthode de segmentation utilisée. Et depuis les différentes images résultats de la segmentation, le système automatique en choisit la meilleure, et la fournit en sortie. Ceci est résumé sur la figure (Fig 3.14).

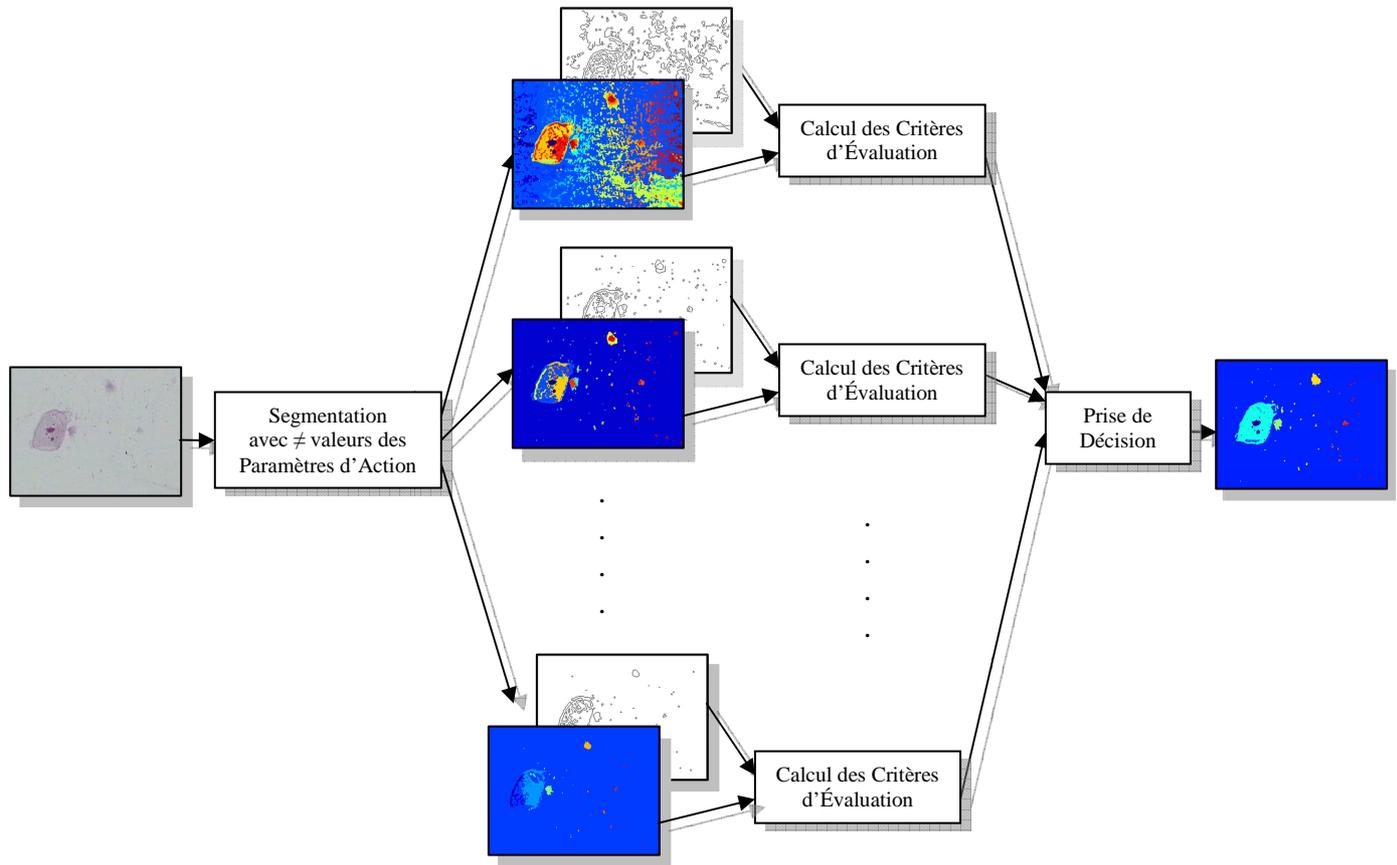


Fig 3.14. Illustration de la première approche de segmentation automatique.

L'image exemple que nous avons pris pour notre application est illustrée sur la figure (Fig 3.15-a). Les images de (Fig 3.15-b) et (Fig 3.15-c) représentent les deux images référence (ou vérité terrain) nécessaires pour l'évaluation supervisée de la segmentation approche région et approche contour respectivement. Elles représentent les segmentations idéales.

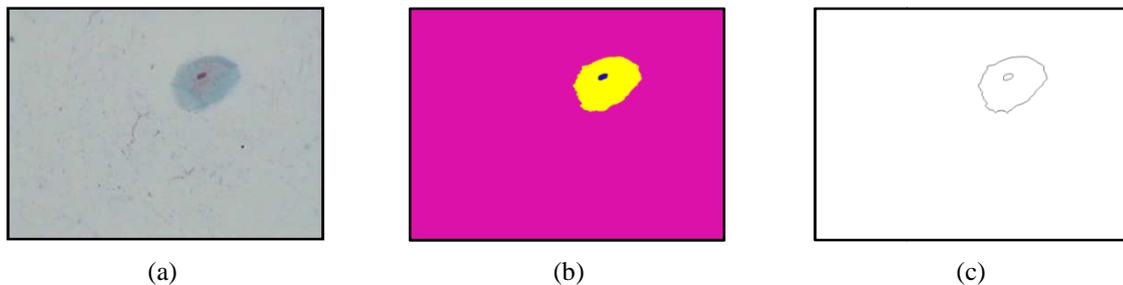


Fig 3.15. Image test de l'application (a) et ses deux images référence : (b) régions, (c) contours.

A partir de l'image originale, nous appliquons notre méthode de segmentation en régions et en contours expliquées dans le paragraphe (§ 3.3). Nous reconnaissons les paramètres d'action et les paramètres de performance. Les paramètres d'action sont les paramètres du FCM, c'est à dire:

- Le nombre de classes,
- L'indice flou m .

Un choix d'une grande valeur du paramètre "nombre de classes" provoque une présence de plusieurs classes dans l'image classifiée et par conséquent un nombre relativement grand du nombre de régions dans l'image segmentée. Ceci n'implique pas forcément qu'un choix d'une petite valeur du nombre de classes, donne un résultat meilleur, puisqu'un choix plus petit que le nombre d'objets présents dans l'image provoque une sous-segmentation (par exemple

suppression du noyau dans l'image cytologique). Quant au deuxième paramètre d'action, plus m est grand plus le degré d'appartenance des différents pixels augmente, ce qui isole d'avantage les pixels appartenant éventuellement à la même classe. Ceci peut provoquer une mauvaise segmentation. Dans ce qui suit nous allons voir l'influence de ces deux paramètres sur le résultat de la segmentation des images cytologiques couleur, et donc sur les critères de performance.

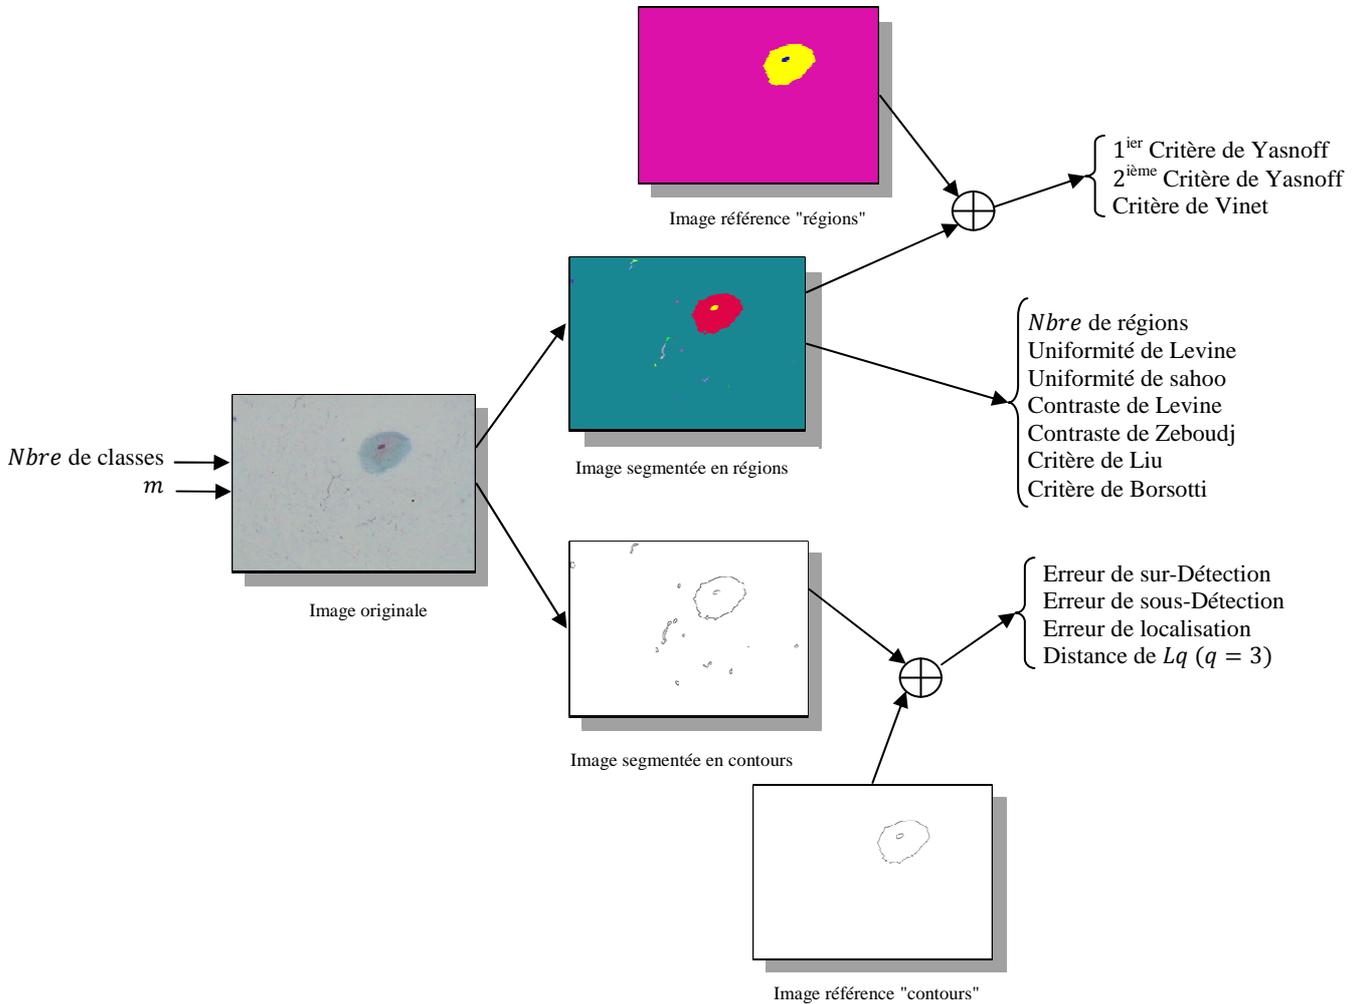


Fig 3.16. Processus de la segmentation et du calcul des critères de performance.

Les critères de performance qui sont des critères d'évaluation sont :

- Nombre de régions, → Critère considéré comme non supervisé
 - Premier critère de Yasnoff,
 - Deuxième critère de Yasnoff,
 - Critère de Vinet,
 - Uniformité de Levine et Nazif,
 - Uniformité de Sahoo,
 - Contraste de Levine et Nazif,
 - Contraste de Zeboudj,
 - Critère de Liu,
 - Critère de Borsotti,
 - Erreur de sur-détection,
 - Erreur de sous-détection,
 - Erreur de localisation,
 - Distance Lq pour $q = 3$.
- Critères supervisés (segmentation en régions)
 Critères non supervisés (segmentation en régions)
 Critères supervisés (segmentation en contours)

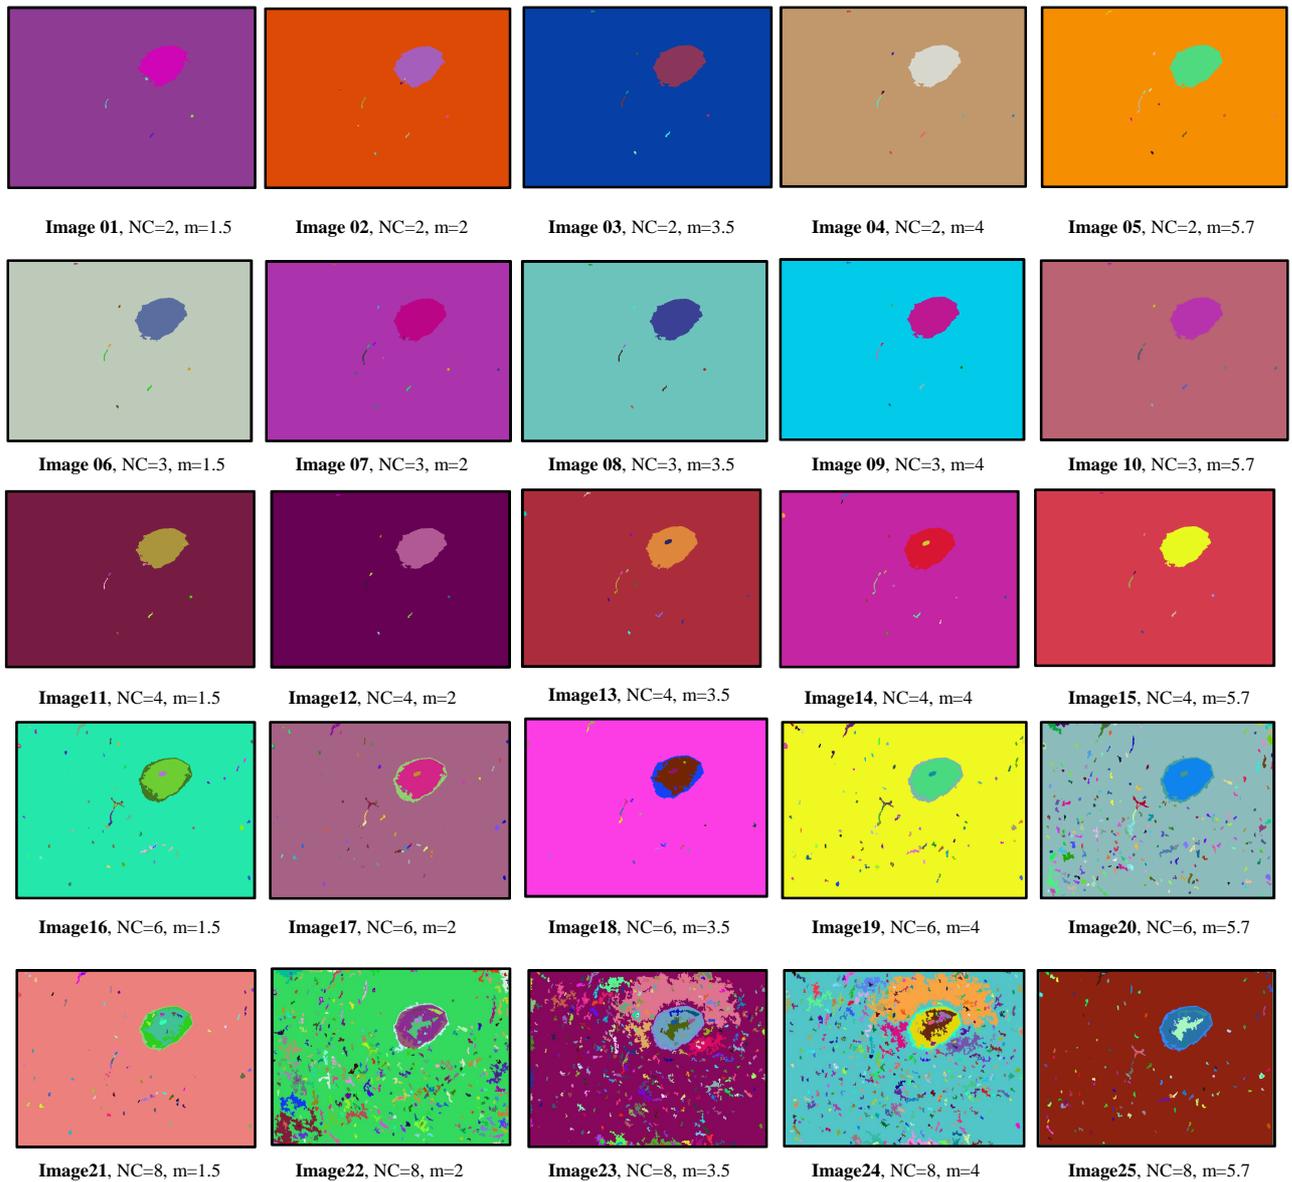


Fig 3.17. Résultats de la segmentation en régions de l'image test pour les valeurs des deux paramètres d'action: $NC = \{2, 3, 4, 6, 8\}$, $m = \{1.5, 2, 3.5, 4, 5.7\}$.

Nous rappelons que l'indication des différents critères de performance pour une bonne segmentation est donnée comme suit:

- Nombre de régions : *de petite valeur*,
- Premier critère de Yasnoff : *proche de 0*,
- Deuxième critère de Yasnoff : *proche de 1*,
- Critère de Vinet : *proche de 1*,
- Uniformité de Levine et Nazif : *proche de 1*,
- Uniformité de Sahoo : *proche de 1*,
- Contraste de Levine et Nazif : *proche de 0*,
- Contraste de Zeboudj : *proche de 0*,
- Critère de Liu : *proche de 0*,
- Critère de Borsotti : *proche de 0*,
- Erreur de sur-détection : *proche de 0*,
- Erreur de sous-détection : *proche de 0*,
- Erreur de localisation : *proche de 0*,
- Distance L_q : *proche de 0*.

La figure (Fig 3.16) schématise tout le processus effectué pour l'évaluation des segmentations lors de l'application pour un choix approprié des paramètres d'action. Notons que le nombre de régions est considéré comme un critère non supervisé puisque nous le calculons à partir de l'image segmentée seulement.

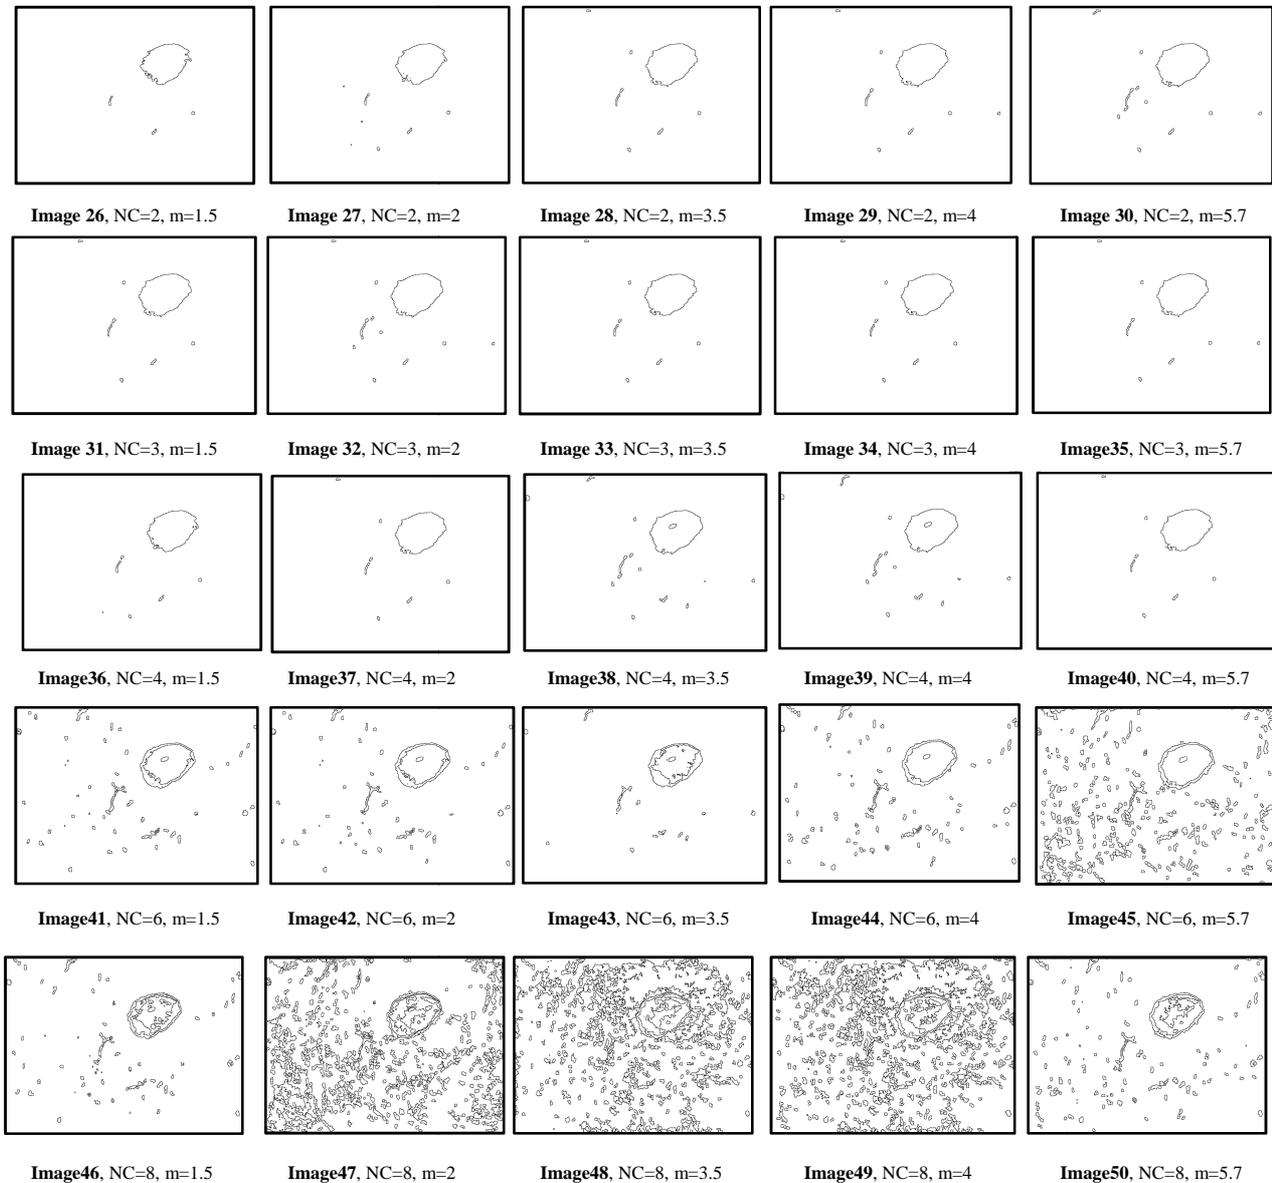


Fig 3.18. Résultats de la segmentation en contours correspondant aux différents résultats de la segmentation en régions.

Pour de différentes valeurs de "Nombre de classes" et de " m " nous effectuons la segmentation en régions et en contours et nous calculons les critères de performance correspondants. Nous avons pris : Nbre de classes = $\{2, 3, 4, 6, 8\}$, et $m = \{1.5, 2, 3.5, 4, 5.7\}$. Le choix de ces valeurs est effectué expérimentalement après plusieurs essais (vu que la segmentation est sensible aux paramètres d'action) de manière à couvrir une grande majorité des segmentations.

Les résultats de la segmentation en régions sont présentés sur la figure (Fig 3.17). Les critères d'évaluation calculés pour chaque image "régions" résultat sont illustrés sur le tableau (**Tableau 1**) pour les critères supervisés et sur le tableau (**Tableau 3**) pour les critères non supervisés. Et les résultats de la segmentation en contours sont présentés sur la figure (Fig 3.18).

Les critères d'évaluation supervisés calculés pour chaque image "contours" résultat sont illustrés sur le tableau (Tableau 2). Les diagrammes des figures (Fig 3.19), (Fig 3.20), (Fig 3.21) et (Fig 3.22) illustrent l'influence des deux paramètres d'action sur les critères de performance.

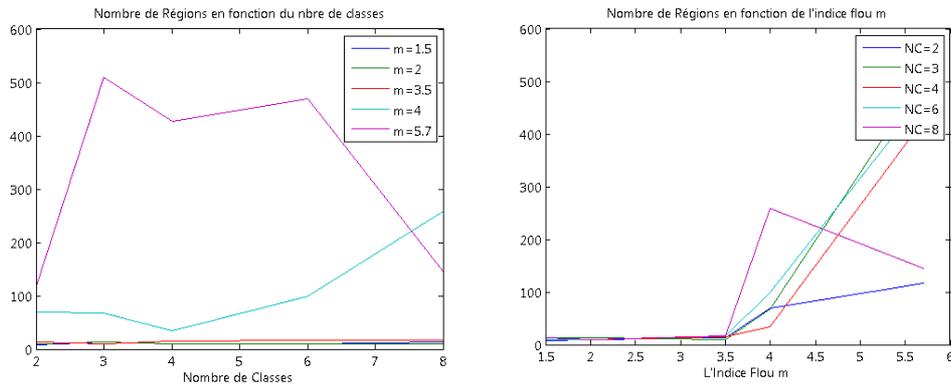


Fig 3.19. Influence du Nombre de classes et de l'indice flou m sur le nombre de régions de l'image segmentée.

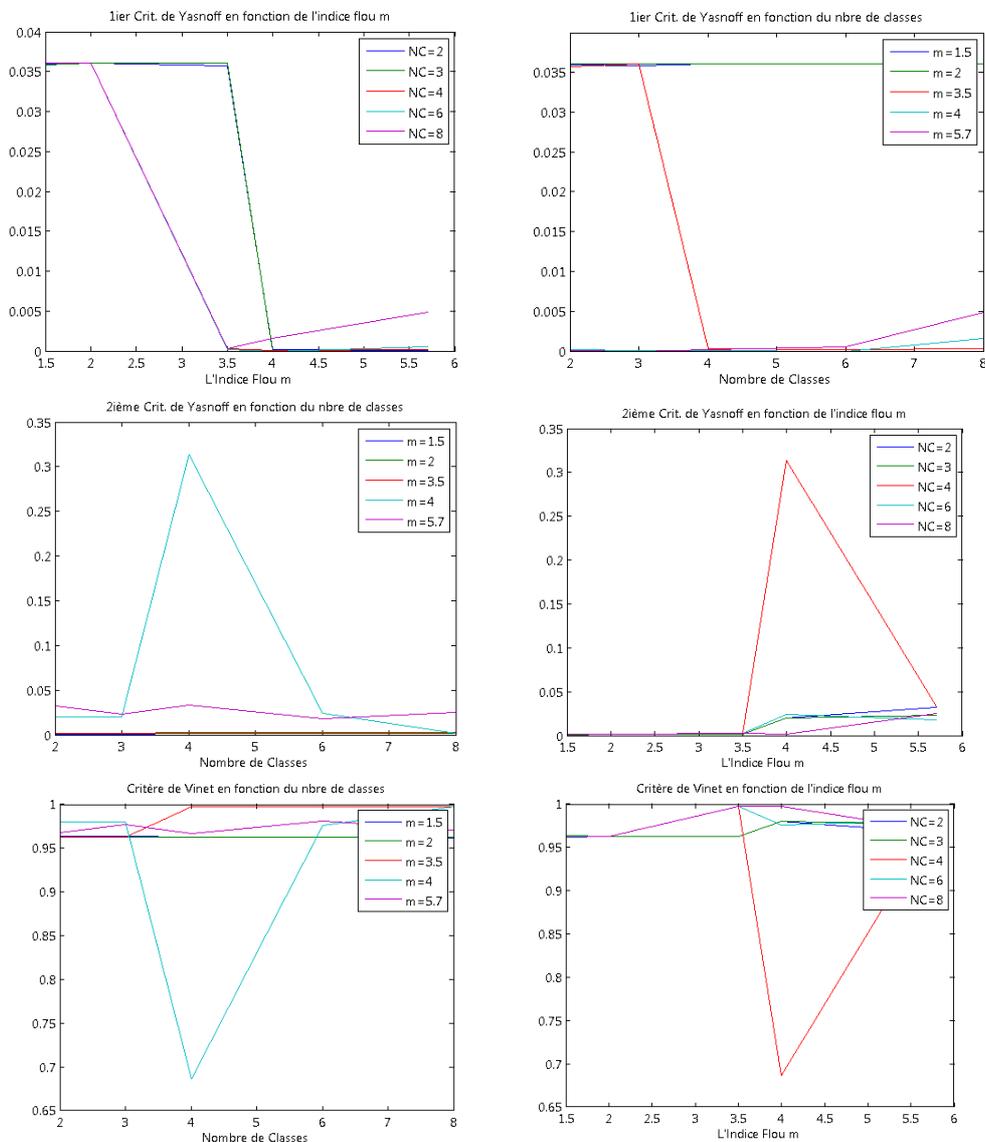


Fig 3.20. Influence du Nombre de classes et de l'indice flou m sur les critères supervisés de l'évaluation de la segmentation en régions.

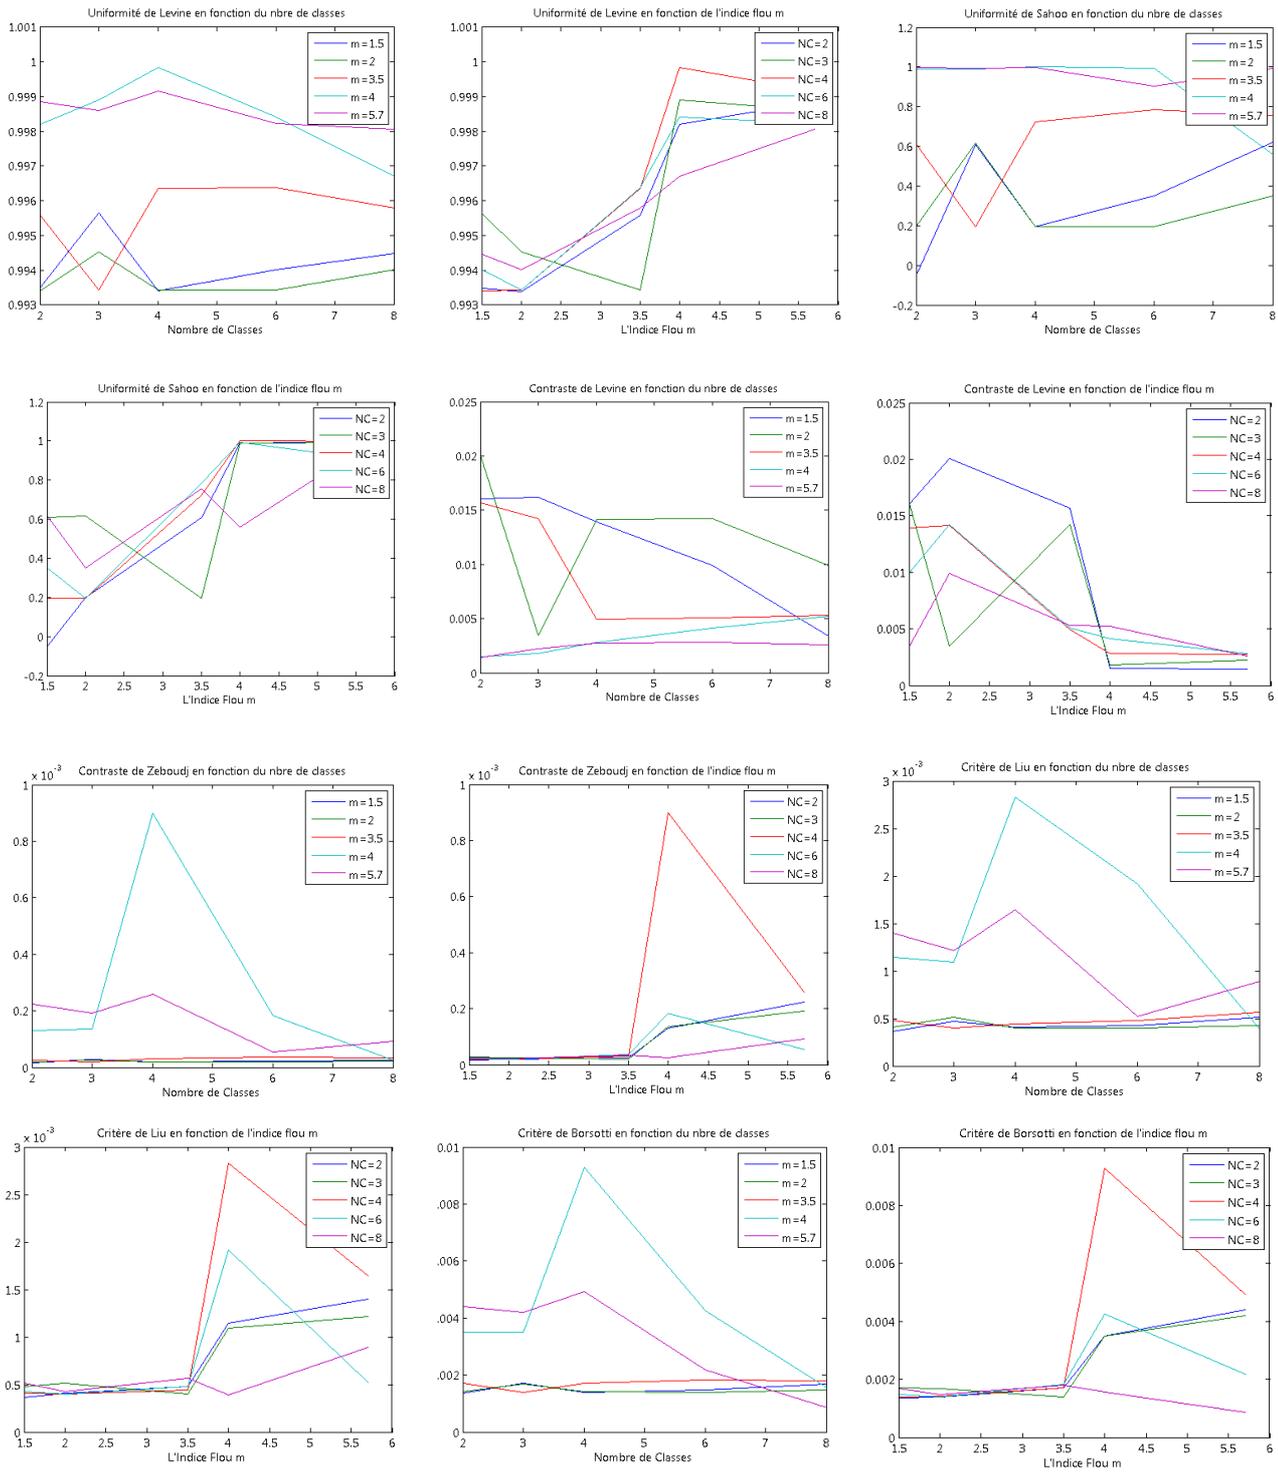


Fig 3.21. Influence du Nombre de classes et de l'indice flou m sur les critères non supervisés de l'évaluation de la segmentation en régions.

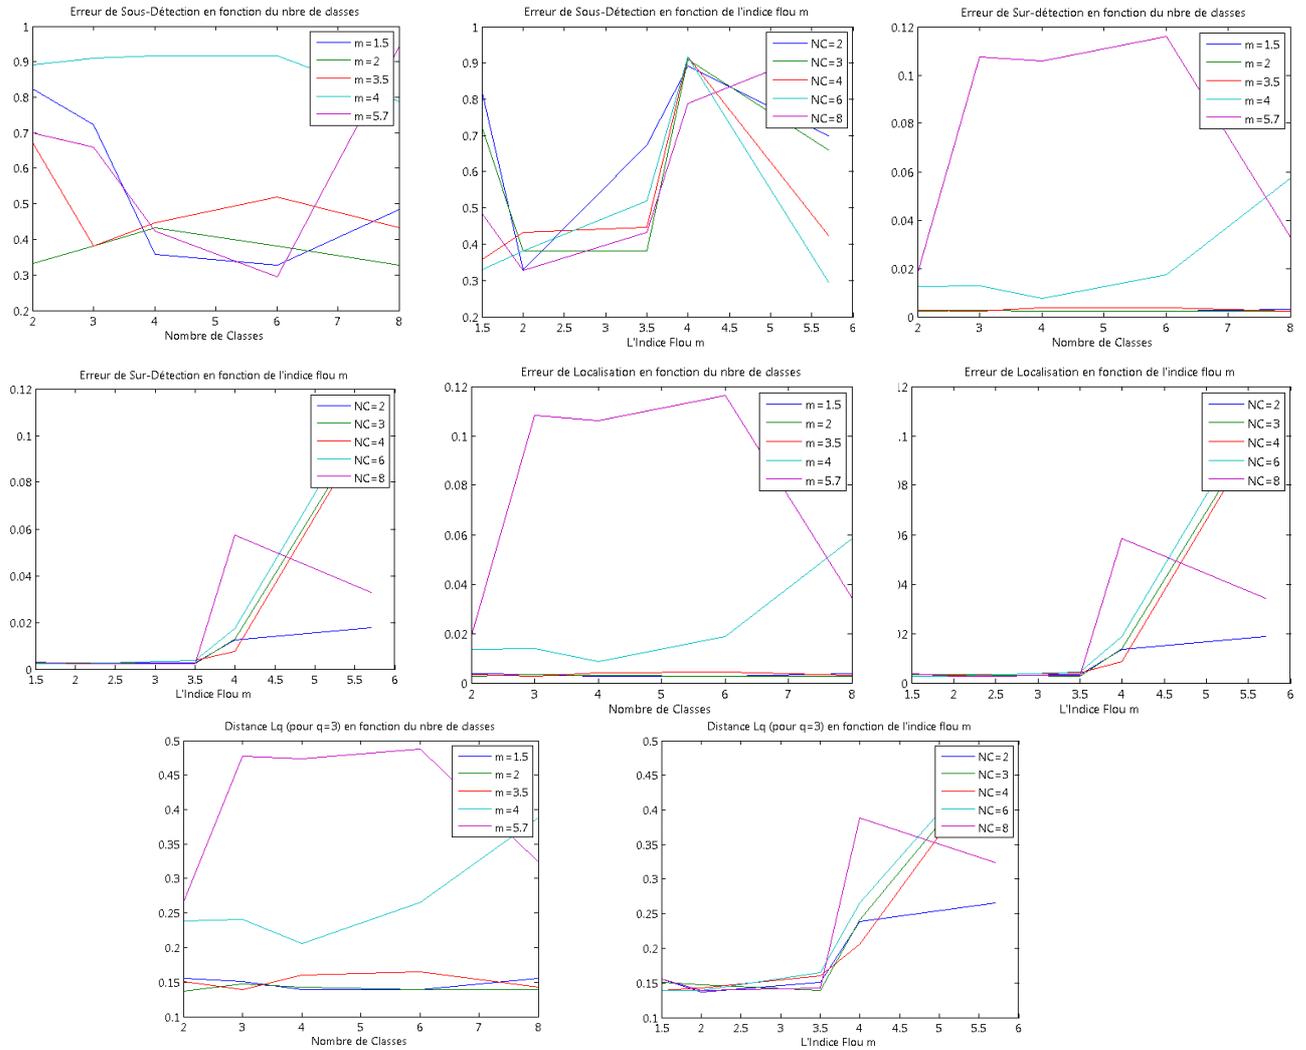


Fig 3.22. Influence du Nombre de classes et de l'indice flou m sur les critères supervisés de l'évaluation de la segmentation en contours.

Tableau 1. Calcul des critères supervisés pour l'évaluation de la segmentation en régions.

Image résultat	Nbre Classes	m	1 ^{er} crit. de Yasnoff	2 ^{ème} crit. de Yasnoff	Vinet
1	2	1.5	0.0360	0.0006	0.9634
2	2	2	0.0359	0.0009	0.9632
3	2	3.5	0.0361	0.0012	0.9627
4	2	4	0.0361	0.0013	0.9626
5	2	5.7	0.0361	0.0020	0.9619
6	3	1.5	0.0361	0.0012	0.9627
7	3	2	0.0361	0.0017	0.9622
8	3	3.5	0.0361	0.0011	0.9628
9	3	4	0.0361	0.0011	0.9628
10	3	5.7	0.0361	0.0013	0.9626
11	4	1.5	0.0358	0.0011	0.9631
12	4	2	0.0361	0.0011	0.9628
13	4	3.5	0.0003	0.0023	0.9973
14	4	4	0.0002	0.3136	0.9973
15	4	5.7	0.0003	0.0026	0.9971
16	6	1.5	0.0002	0.0200	0.9798
17	6	2	0.000134	0.0202	0.9798
18	6	3.5	0.000786	0.0025	0.6863
19	6	4	0.0002	0.0245	0.9755
20	6	5.7	0.0015	0.0013	0.9971
21	8	1.5	0.000027	0.0324	0.9676
22	8	2	0.000057	0.0228	0.9772
23	8	3.5	0.0001	0.0332	0.9666
24	8	4	0.0005	0.0180	0.9815
25	8	5.7	0.0049	0.0247	0.9705

Tableau 2. Calcul des critères supervisés pour l'évaluation de la segmentation en contours.

Image résultat	Nbre Classes	m	Erreur de sous-détection	Erreur de sur-détection	Erreur de Localisation	Distance Lq
26	2	1.5	0.823529	0.002677	0.003797	0.156008
27	2	2	0.723039	0.002479	0.003462	0.151285
28	2	3.5	0.357843	0.002177	0.002663	0.138607
29	2	4	0.328431	0.002218	0.002663	0.138607
30	2	5.7	0.485294	0.003099	0.003757	0.155456
31	3	1.5	0.330882	0.002114	0.002563	0.136844
32	3	2	0.382353	0.002707	0.003225	0.147743
33	3	3.5	0.433824	0.002298	0.002887	0.142392
34	3	4	0.382353	0.002198	0.002716	0.139530
35	3	5.7	0.328431	0.002218	0.002663	0.138607
36	4	1.5	0.674020	0.002543	0.003459	0.151236
37	4	2	0.382353	0.002198	0.002716	0.139530
38	4	3.5	0.446078	0.003514	0.004118	0.160288
39	4	4	0.519608	0.003809	0.004513	0.165254
40	4	5.7	0.433824	0.002298	0.002887	0.142392
41	6	1.5	0.892157	0.012438	0.013639	0.238925
42	6	2	0.909314	0.012763	0.013987	0.240940
43	6	3.5	0.916667	0.007504	0.008745	0.206024
44	6	4	0.916667	0.017467	0.018694	0.265400
45	6	5.7	0.789216	0.057314	0.058313	0.387783
46	8	1.5	0.698529	0.017792	0.018721	0.265526
47	8	2	0.659314	0.107543	0.108297	0.476656
48	8	3.5	0.424020	0.105808	0.106242	0.473623
49	8	4	0.294118	0.116103	0.116346	0.488184
50	8	5.7	0.943627	0.032803	0.034046	0.324107

Tableau 3. Calcul des critères non supervisés pour l'évaluation de la segmentation en régions.

Image résultat	Nbre Classes	m	Nombre d'Étiquettes	U. Levine	U. Sahoo	C.Levine	C.Zeboudj	Liu	Borsotti
1	2	1.5	8	0.9935	0.0521	0.0160	0.0154×10⁻³	0.0003	0.0014
2	2	2	13	0.9956	0.6083	0.0162	0.0268×10 ⁻³	0.0005	0.0017
3	2	3.5	9	0.9934	0.1966	0.0139	0.0189×10 ⁻³	0.0004	0.0014
4	2	4	10	0.9940	0.3507	0.0099	0.0211×10 ⁻³	0.0004	0.0015
5	2	5.7	13	0.9945	0.6198	0.0034	0.0257×10 ⁻³	0.0005	0.0017
6	3	1.5	9	0.9934	0.1972	0.0201	0.0190×10 ⁻³	0.0004	0.0014
7	3	2	13	0.9945	0.6182	0.0035	0.0258×10 ⁻³	0.0005	0.0017
8	3	3.5	9	0.9934	0.1951	0.0141	0.0191×10 ⁻³	0.0004	0.0014
9	3	4	9	0.9934	0.1958	0.0143	0.0192×10 ⁻³	0.0004	0.0014
10	3	5.7	10	0.9940	0.3507	0.0099	0.0211×10 ⁻³	0.0004	0.0015
11	4	1.5	13	0.9956	0.6104	0.0157	0.0259×10 ⁻³	0.0005	0.0017
12	4	2	9	0.9934	0.1958	0.0143	0.0192×10 ⁻³	0.0004	0.0014
13	4	3.5	15	0.9964	0.7245	0.0049	0.0319×10 ⁻³	0.0004	0.0017
14	4	4	17	0.9998	0.9997	0.0050	0.0374×10 ⁻³	0.0028	0.0093
15	4	5.7	16	0.9958	0.7565	0.0053	0.0343×10 ⁻³	0.0006	0.0018
16	6	1.5	70	0.9982	0.9881	0.0015	0.1305×10 ⁻³	0.0011	0.0035
17	6	2	68	0.9989	0.9872	0.0018	0.1359×10 ⁻³	0.0011	0.0035
18	6	3.5	35	0.9964	0.7859	0.0028	0.8984×10 ⁻³	0.0005	0.0018
19	6	4	99	0.9984	0.9939	0.0041	0.1813×10 ⁻³	0.0019	0.0042
20	6	5.7	259	0.9967	0.5603	0.0052	0.0253×10 ⁻³	0.0004	0.0016
21	8	1.5	116	0.9989	0.9955	0.0014	0.2232×10 ⁻³	0.0014	0.0044
22	8	2	510	0.9986	0.9940	0.0023	0.1923×10 ⁻³	0.0012	0.0042
23	8	3.5	428	0.9992	0.9967	0.0027	0.2582×10 ⁻³	0.0016	0.0049
24	8	4	469	0.9982	0.9013	0.0028	0.0551×10 ⁻³	0.0005	0.0022
25	8	5.7	145	0.9981	0.9948	0.0026	0.0907×10 ⁻³	0.0009	0.0009

En étudiant les quatre figures et les trois tableaux illustrant l'influence des paramètres d'action sur les critères d'évaluation, nous avons repéré l'indication de chaque critère pour la meilleure segmentation (indiquée sur les tableaux en caractère gras). En comparant cette indication avec les images résultats de la segmentation (Fig 3.17) et (Fig 3.18) qui montrent de façon visuelle que la meilleure segmentation correspond à $NC = 4$ et $m = \{3.5 \text{ ou } 4\}$, nous avons conclu que les critères qui sont fiables sont :

- Deuxième critère de Yasnoff : *proche de 1*,
- Critère de Vinet : *proche de 1*,
- Uniformité de Levine et Nazif : *proche de 1*,
- Uniformité de Sahoo : *proche de 1*,

La fiabilité des ces critères est probablement liée au type des images d'application, cependant nous ne pouvons donner preuves d'explication à cette hypothèse. Sachant que ces résultats ont été pratiquement les mêmes pour plusieurs images test, et ainsi pour la généralisation de ce système de segmentation automatique, nous concluons que la meilleure segmentation doit correspondre au maximum de chacun de ces quatre critères.

3.5.2 Deuxième approche

La première approche nous a permis d'avoir une idée pratique sur le comportement des indicateurs de performance selon les valeurs des paramètres d'action pour une application sur des images cytologiques couleur. Nous proposons une deuxième approche, qui met en œuvre un système automatique qui a pour but d'améliorer le résultat de la segmentation en agissant sur les paramètres d'action de la méthode de segmentation utilisée et cela selon les indicateurs de performance qui servent à l'évaluer. A partir de ces critères, le système passe par un contrôleur basé sur des règles floues pour donner en sortie de ce contrôleur de nouvelles valeurs des paramètres d'action de la méthode de segmentation utilisée. Le système continue la correction de la segmentation jusqu'à obtention de la meilleure segmentation. Ceci est illustré sur le schéma de la figure (Fig 3.23).

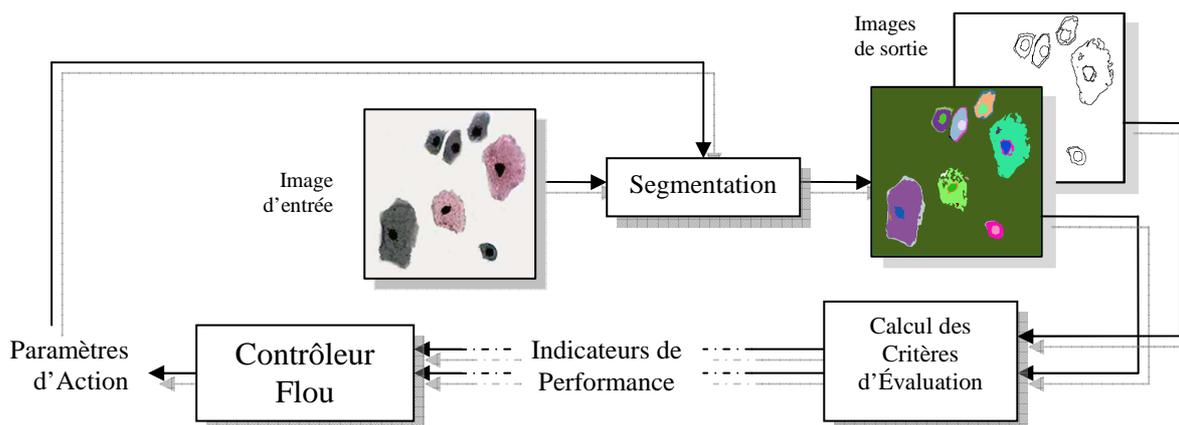


Fig 3.23. Schéma général de la deuxième approche de la segmentation automatique.

Notamment nous donnons l'organigramme correspondant qui détaille le processus de ce deuxième système de segmentation automatique sur la figure (Fig 3.24). A partir de l'image originale (après avoir effectué le filtrage) et des valeurs initiales des paramètres d'action, il suit les différentes étapes données comme suit:

1. Appliquer l'algorithme de Classification Fuzzy- *C*-Means,
2. Effectuer un étiquetage suivi d'une correction en éliminant les petites régions et aussi les effets de bord,
3. Calculer les critères d'évaluation de la segmentation en régions, de type supervisé et non supervisé,
4. Effectuer une segmentation en contours,
5. Calculer les critères supervisés d'évaluation de la segmentation en contours,
6. Appliquer la commande floue qui compose le contrôleur flou,
7. Récupérer les nouvelles valeurs des paramètres d'action,
8. Utiliser les critères d'évaluation pour qualifier le résultat de la segmentation, si elle est qualifiée de bonne on arrête le processus, sinon retour à la première étape.

Le régulateur flou se base sur la théorie floue. Le principe de la théorie floue [17,18] est de donner des degrés d'appartenance des paramètres à une certaine classe. Par exemple dire qu'un paramètre est grand à 30% et petit à 70%, au lieu de le qualifier comme étant petit. Principalement, le contrôleur flou passe par trois étapes : la fuzzification des entrées, l'application des règles floues et la défuzzification des sorties, comme montré sur la figure (Fig 3.25). La fuzzification consiste à donner à une certaine valeur de l'entrée un degré d'appartenance aux différentes "classes", en se basant sur la fonction d'appartenance du paramètre. La défuzzification est l'opération inverse de la fuzzification. Elle traduit l'appartenance du paramètre aux classes en une valeur réelle en se basant sur la fonction d'appartenance.

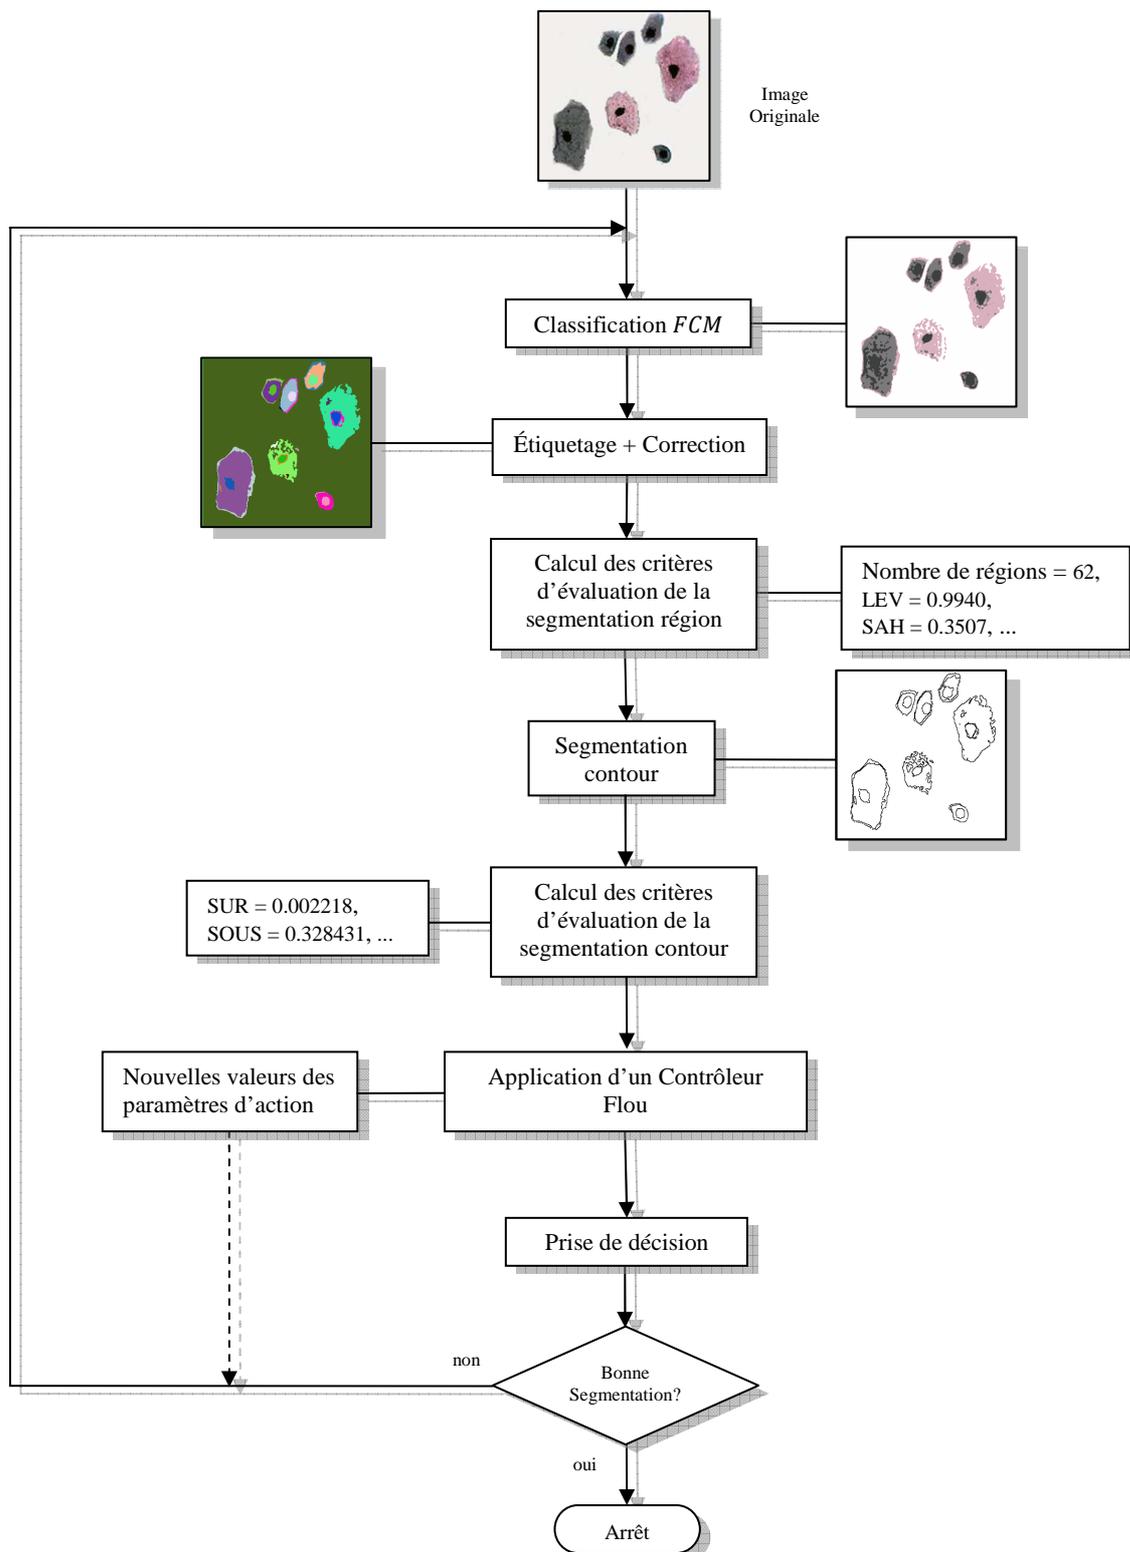


Fig 3.24. Organigramme de la méthode appliquée de la deuxième approche de la segmentation automatique.

Nous avons pris comme entrées pour le contrôleur flou deux critères de performances. Nous avons pris deux critères seulement et non pas plus pour ne pas compliquer la mise au point du contrôleur flou vu la difficulté de prononcer des règles floues qui est une tâche très délicate. Cependant parmi les critères ayant fait l'objet de déduction de fiabilité pour la première méthode de segmentation automatique, nous en avons choisi deux critères d'évaluation. Il s'agit de : l'uniformité de Levine et l'uniformité de Sahoo. Ce choix est fait pour deux raisons :

- Suite à des essais expérimentaux.
- Nous avons préféré ne prendre que les critères supervisés pour ne pas être amené à définir une image vérité terrain pour chaque nouveau traitement, ceci rend le système entièrement automatique. D'autant plus que le calcul des critères supervisés est très sensible à la variation de l'image vérité terrain.

Nous avons ainsi défini les fonctions d'appartenance des deux entrées qui sont illustrées sur la figure (Fig 3.26). nous procédons de même pour la définition des fonctions d'appartenance des sorties qui sont le nombre de classes et l'indice flou m , et qui sont représentées sur la figure (Fig 3.27). Les classes des fonctions d'appartenance de chaque entrée sont : {petit, moyen, grand, très grand} et les classes des fonctions d'appartenance de chacune des deux sorties sont : {petit, moyen, grand}.

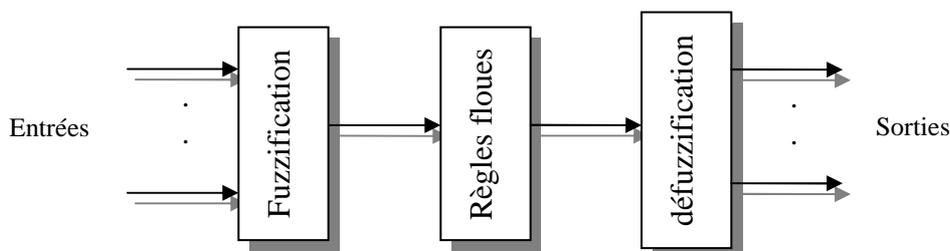


Fig 3.25. Les trois étapes du contrôleur flou.

Après avoir effectué un certain nombre de tests (essais), nous avons défini les règles floues suivantes :

SI *U.Levine est petit* **ET** *U.Sahoo est petit* **ALORS** *le Nombre de Classes est grand*,
SI *U.Levine est petit* **ET** *U.Sahoo est moyen* **ALORS** *le Nombre de Classes est moyen*,
SI *U.Levine est moyen* **ET** *U.Sahoo est petit* **ALORS** *le Nombre de Classes est moyen*,
SI *U.Levine est très grand* **ET** *U.Sahoo est très grand* **ALORS** *le Nombre de Classes est petit*,

SI *U.Levine est petit* **ET** *U.Sahoo est petit* **ALORS** *l'Indice Flou est grand*,
SI *U.Levine est petit* **ET** *U.Sahoo est moyen* **ALORS** *l'Indice Flou est grand*,
SI *U.Levine est moyen* **ET** *U.Sahoo est petit* **ALORS** *l'Indice Flou est grand*,
SI *U.Levine est très grand* **ET** *U.Sahoo est très grand* **ALORS** *l'Indice Flou est moyen*.

Nous avons choisi les opérateurs *min* et *max* pour les opérations : *ET* et *OU* respectivement. Ce choix est fait selon la fiabilité de ces opérateurs qui est assez connue dans le domaine de la théorie de la logique floue. Ces deux opérateurs ont été présentés dans le paragraphe (§ 1.4.3) du chapitre 1. Nous précisons que *OU* lie les différentes règles floues.

La troisième étape du contrôleur flou, qui est la défuzzification, est basée sur le calcul du "centre de gravité" présenté dans (§ 1.4.7) du chapitre 1.

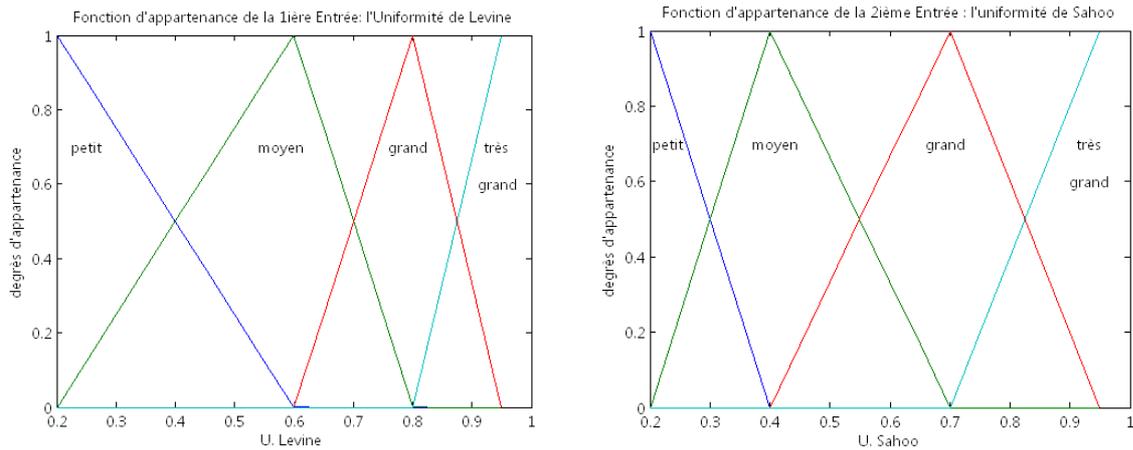


Fig 3.26. Les fonctions d'appartenance des entrées du contrôleur flou.

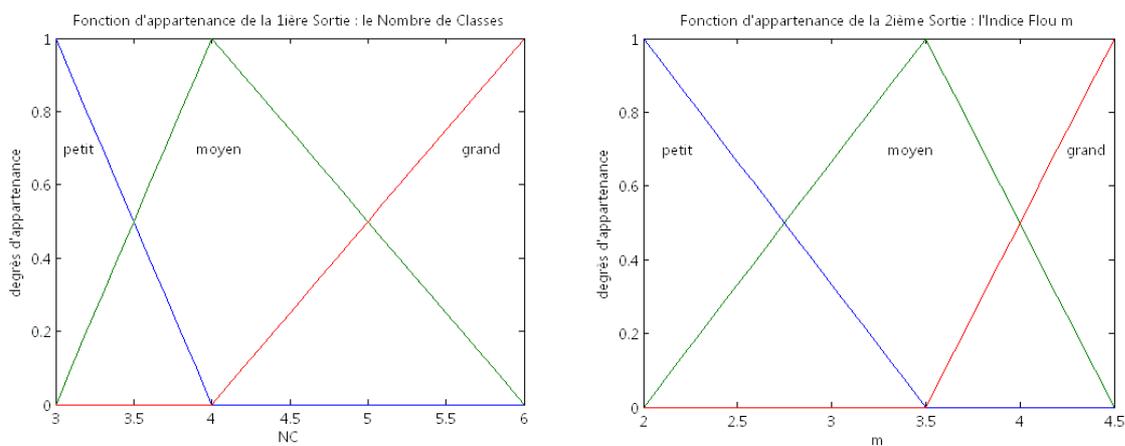


Fig 3.27. Les fonctions d'appartenance des sorties du contrôleur flou.

Pour des valeurs de $NC = 2$ et $m = 1.5$, nous effectuons une première segmentation, pour laquelle nous calculons les critères de performance. Ces critères vont servir comme entrées pour le contrôleur flou qui fournit en sortie, de nouvelles valeurs de NC et de m , afin d'établir une nouvelle segmentation. Le processus continue de la sorte jusqu'à obtention d'une bonne segmentation définie par un degré de qualité qui est un des deux critères de performance d'entrée. Nous avons décidé qu'une bonne segmentation est obtenue lorsque l'uniformité de Levine et Nazif atteint ou dépasse une valeur de : 0.996 , c'est-à-dire : $(U. Levine \geq 0.996)$.

Pour notre exemple d'application nous avons obtenu un résultat de bonne segmentation au bout de onze itérations avec les valeurs des paramètres d'actions : $NC = 4$, $m = 3.8$. Les résultats de la segmentation finale sont représentés sur la figure (Fig 3.28).

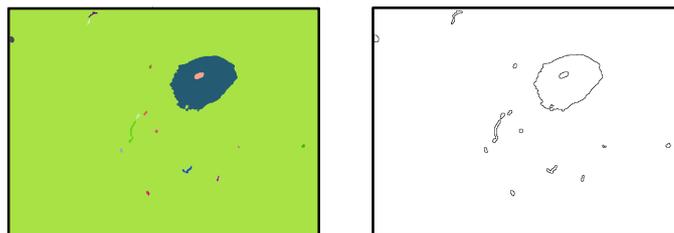


Fig 3.28. Résultats finaux de la deuxième approche de l'exemple de test.

3.6 Conclusion

Nous notons que le but de notre étude est d'assurer une bonne segmentation au cytologiste. Vu que les images cytologiques diffèrent les unes des autres selon leur contenu et leur taille, nous étions amenés à automatiser l'étape de segmentation. Nous sommes arrivés à mettre au point deux systèmes automatiques. Notons que la conception de nos systèmes automatiques a été faite de façon graduelle, issus des essais effectués sur plusieurs images test qui servent d'images d'expérimentation. Nous insistons sur le fait que chaque amélioration apportée était un résultat de plusieurs essais expérimentaux. Le prochain chapitre présente quelques exemples d'application.

Aussi il est à noter que les méthodes de segmentation en régions et en contours que nous avons proposées, se sont montrées assez performantes et ont donné de bons résultats de segmentation.

Chapitre 4

Applications et Résultats

*"Chaque progrès donne un nouvel espoir,
suspendu à la solution d'une nouvelle
difficulté. Le dossier n'est jamais clos."
Claude Lévi-Strauss*

4.1 Introduction

Dans le présent chapitre nous présentons les différents résultats obtenus pour les deux méthodes mises en œuvre de segmentation automatique. Nous avons pris comme images d'application les images cytologiques dans le but de donner des images résultats de segmentation appropriées à être étudiées par le cytologiste. C'est le but principal de ce mémoire de magister. Ceci va être présenté tout au long du paragraphe (§ 4.2) avec douze exemples d'images cytologiques.

Cependant rien ne nous empêche de tester ces méthodes sur d'autres types d'images, de mesurer leur fiabilité dans le cas général et éventuellement proposer des corrections adéquates des critères des deux systèmes automatiques établis. Dans le paragraphe (§ 4.3) nous en donnons quelques exemples.

4.2 Première application : images cytologiques couleur

4.2.1 Acquisition des images cytologiques

L'acquisition des images cytologiques a été faite au sein de l'équipe 'Traitement d'images et Reconnaissance de Formes' du laboratoire 'Signal et Communications' de l'Ecole Nationale Polytechnique. Pour ce faire, nous avons fait appel au laboratoire de cytologie de l'hôpital Hassen Badi, service obstétrique, et qui nous a fourni les échantillons de frottis cervicaux sur lames (Fig 4.1-a). Pour acquérir les images des cellules présentes sur ces lames nous avons utilisé un microscope numérique de type "motic-B1 series" (Fig 4.1-b). Pour chaque prise et en première étape nous plaçons la lamelle sur le microscope en utilisant l'objectif 'ASC 4/0.1, 160/0.17 (4)' (Fig 4.1-c). Ce microscope est lié à un micro-ordinateur équipé d'un logiciel adéquat pour l'acquisition des images (Fig 4.1-d). Il s'agit de 'Motic Images Plus 2.0' (Fig 4.2) qui assure le réglage et le stockage de l'image acquise. Une base de 369 images cytologiques a été construite. Nous avons appliqué nos méthodes sur 106 images de cette base. Parmi ces images nous allons présenter 12 exemples d'images.

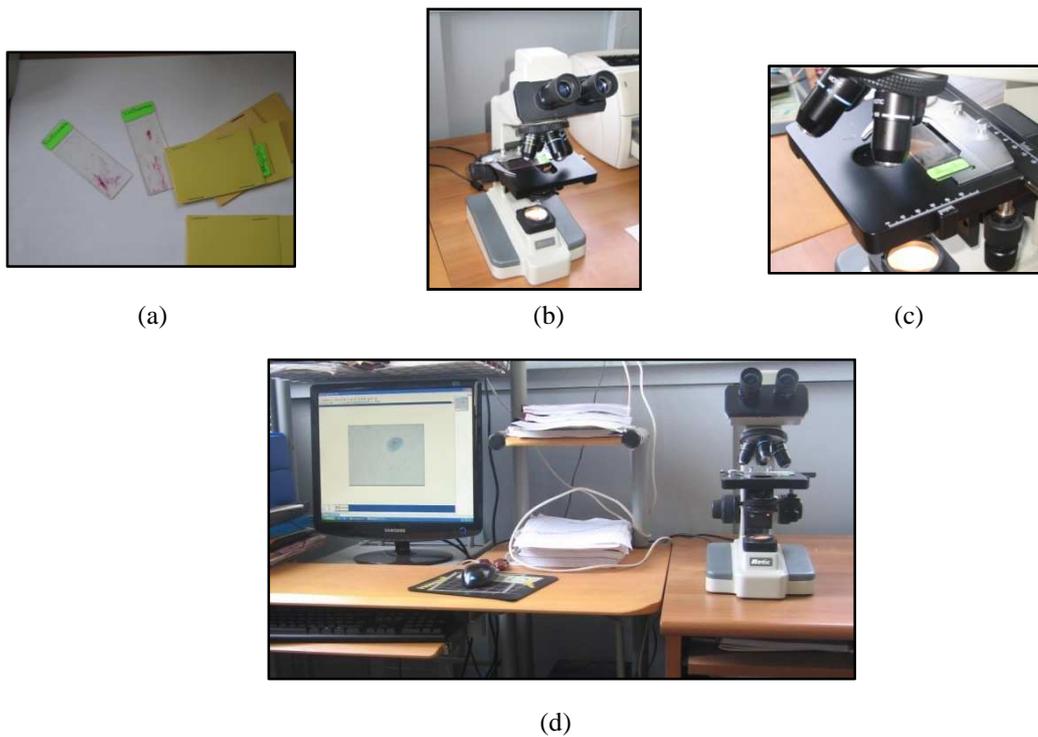


Fig 4.1. Les outils utilisés pour l'acquisition des images cytologiques.

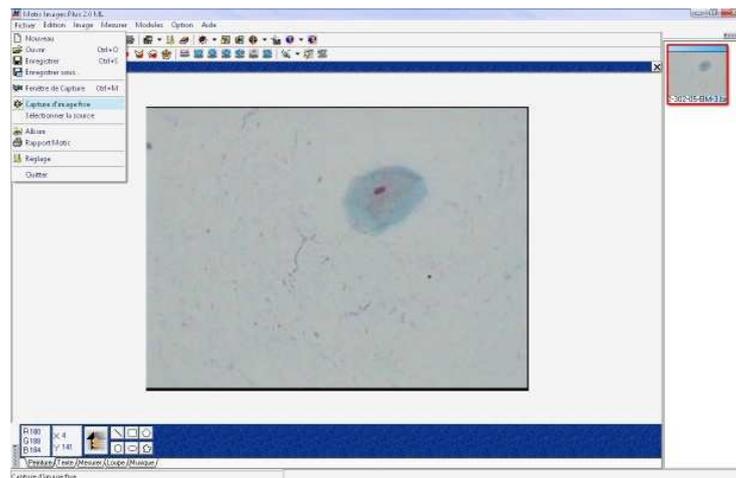


Fig 4.2. Illustration du logiciel d'acquisition d'images microscopiques 'Motic Images Plus 2.0'.

4.2.2 Première approche

Nous présentons ici les résultats obtenus issus de l'application du premier système automatique sur douze exemples d'images cytologiques couleurs acquises au sein du Laboratoire Signal et Communications. Pour chaque exemple nous présentons l'image segmentée en régions et celle segmentée en contours. Dans le premier exemple, il s'agit de l'image que nous avons présentée tout au long du chapitre précédent. Toutefois, nous précisons que nous avons testé notre méthode sur 106 images.

Les résultats obtenus par cette approche appliquée sur les douze images cytologiques sont montrés sur les figures (Fig 4.3) et (Fig 4.4).

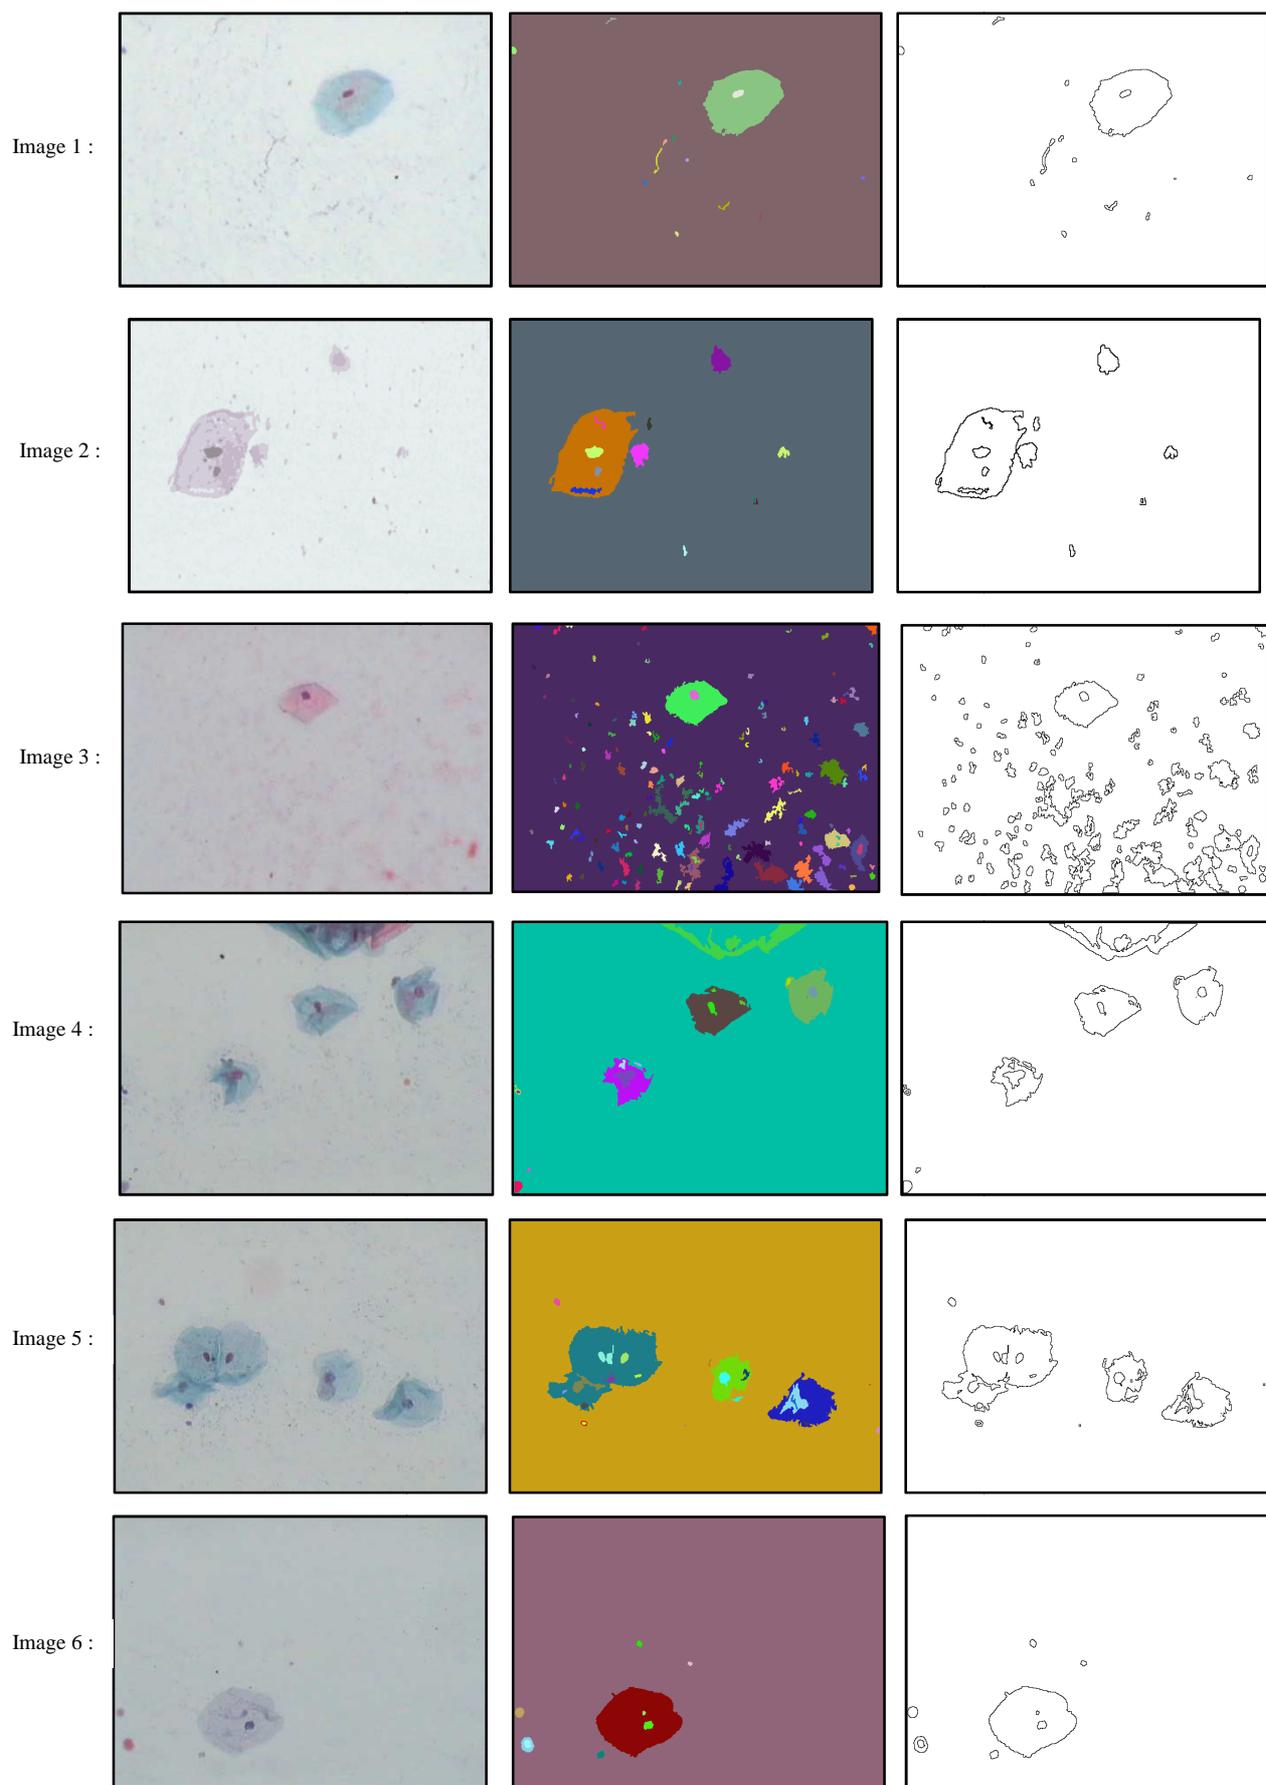


Fig 4.3. Résultats de l'application de la première approche : exemples de la 1^{ière} à la 6^{ième} image.

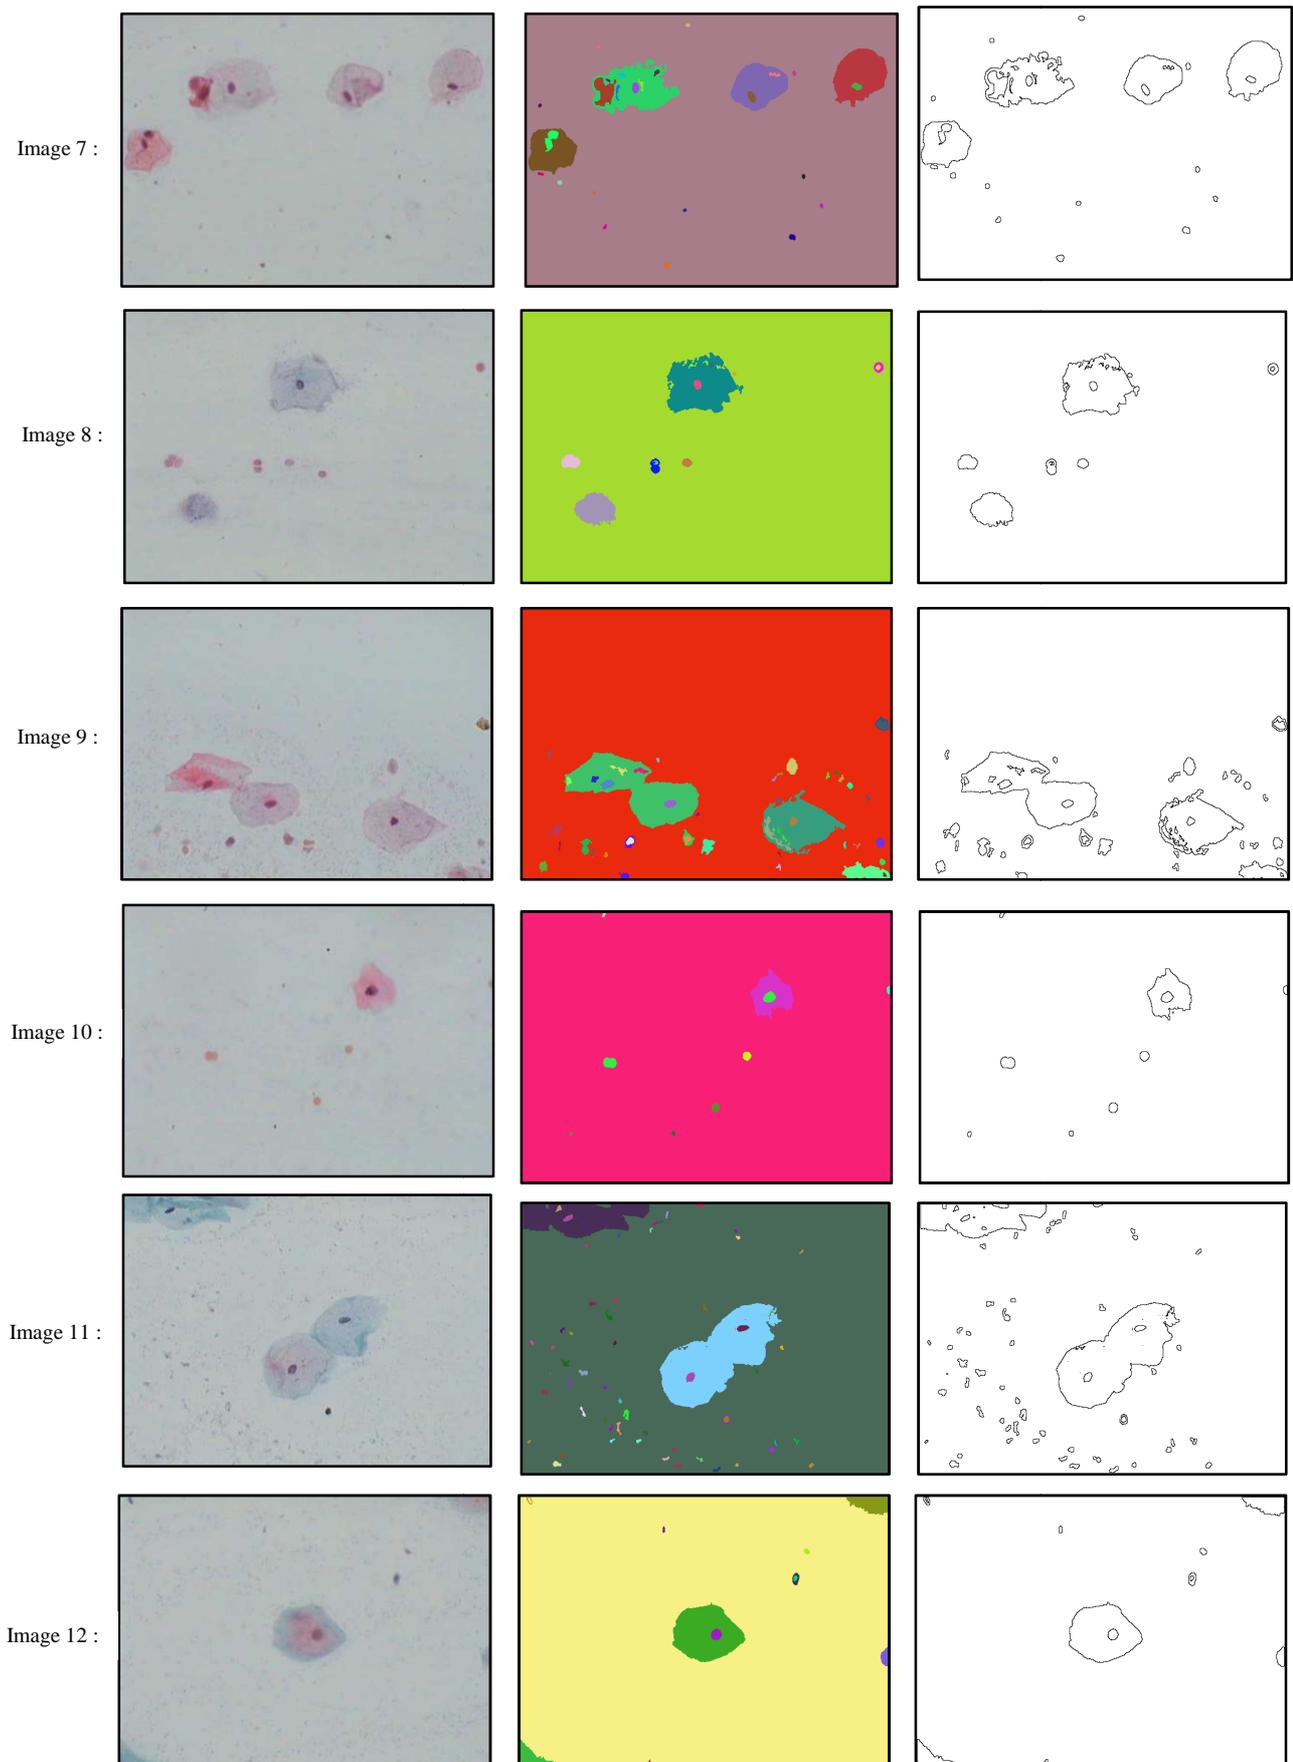


Fig 4.4. Résultats de l'application de la première approche : exemples de la 7^{ième} à la 12^{ième} image.

Ces figures montrent la cohérence des images segmentées résultat avec les images originales correspondantes, vu qu'elles font apparaître les cellules avec leurs noyaux. Ainsi ces résultats sont considérablement bons et présentent une certaine satisfaction.

Notons que la durée de l'application est pratiquement en moyenne de 1 heure 16 minutes et 27 secondes. Moyennement 3 minutes 4 secondes pour chaque itération englobant l'étape de segmentation (en régions et en contours) plus le calcul des quatorze critères d'évaluation. En se basant sur les quatre critères seulement, le coût du processus facteur temps est diminué. Précisons aussi que la durée du traitement est fonction du type et de la taille de l'image traitée.

4.2.3 Deuxième approche

Pour cette approche nous reprenons les mêmes images appliquées au premier système, dans le but de comparer les deux approches.

Les résultats obtenus pour cette approche appliquée sur les douze images cytologiques sont montrés sur les figures (Fig 4.5) et (Fig 4.6).

Nous pouvons juger que les résultats obtenus sont assez bons. Mais en les comparant avec les résultats de la première approche, certaines images résultats paraissent moins bonnes. C'est en moyenne de deux images sur douze (Fig 4.5: image 3, Fig 4.6: image 10), c'est-à-dire 16%. Pour remédier à cela, nous pensons à revoir la définition de notre contrôleur flou, éventuellement au niveau des règles floues, du critère d'arrêt ou encore des fonctions d'appartenance des entrées et des sorties. Pour l'ensemble des images nous avons relevé un pourcentage de 79% de performance du deuxième système automatique, et ceci en comparant ses résultats aux résultats issus de la première approche.

Nous notons qu'en moyenne sur tous les essais appliqués sur les 106 images prises, ce processus a duré pratiquement et en moyenne 52 minutes 36 secondes.

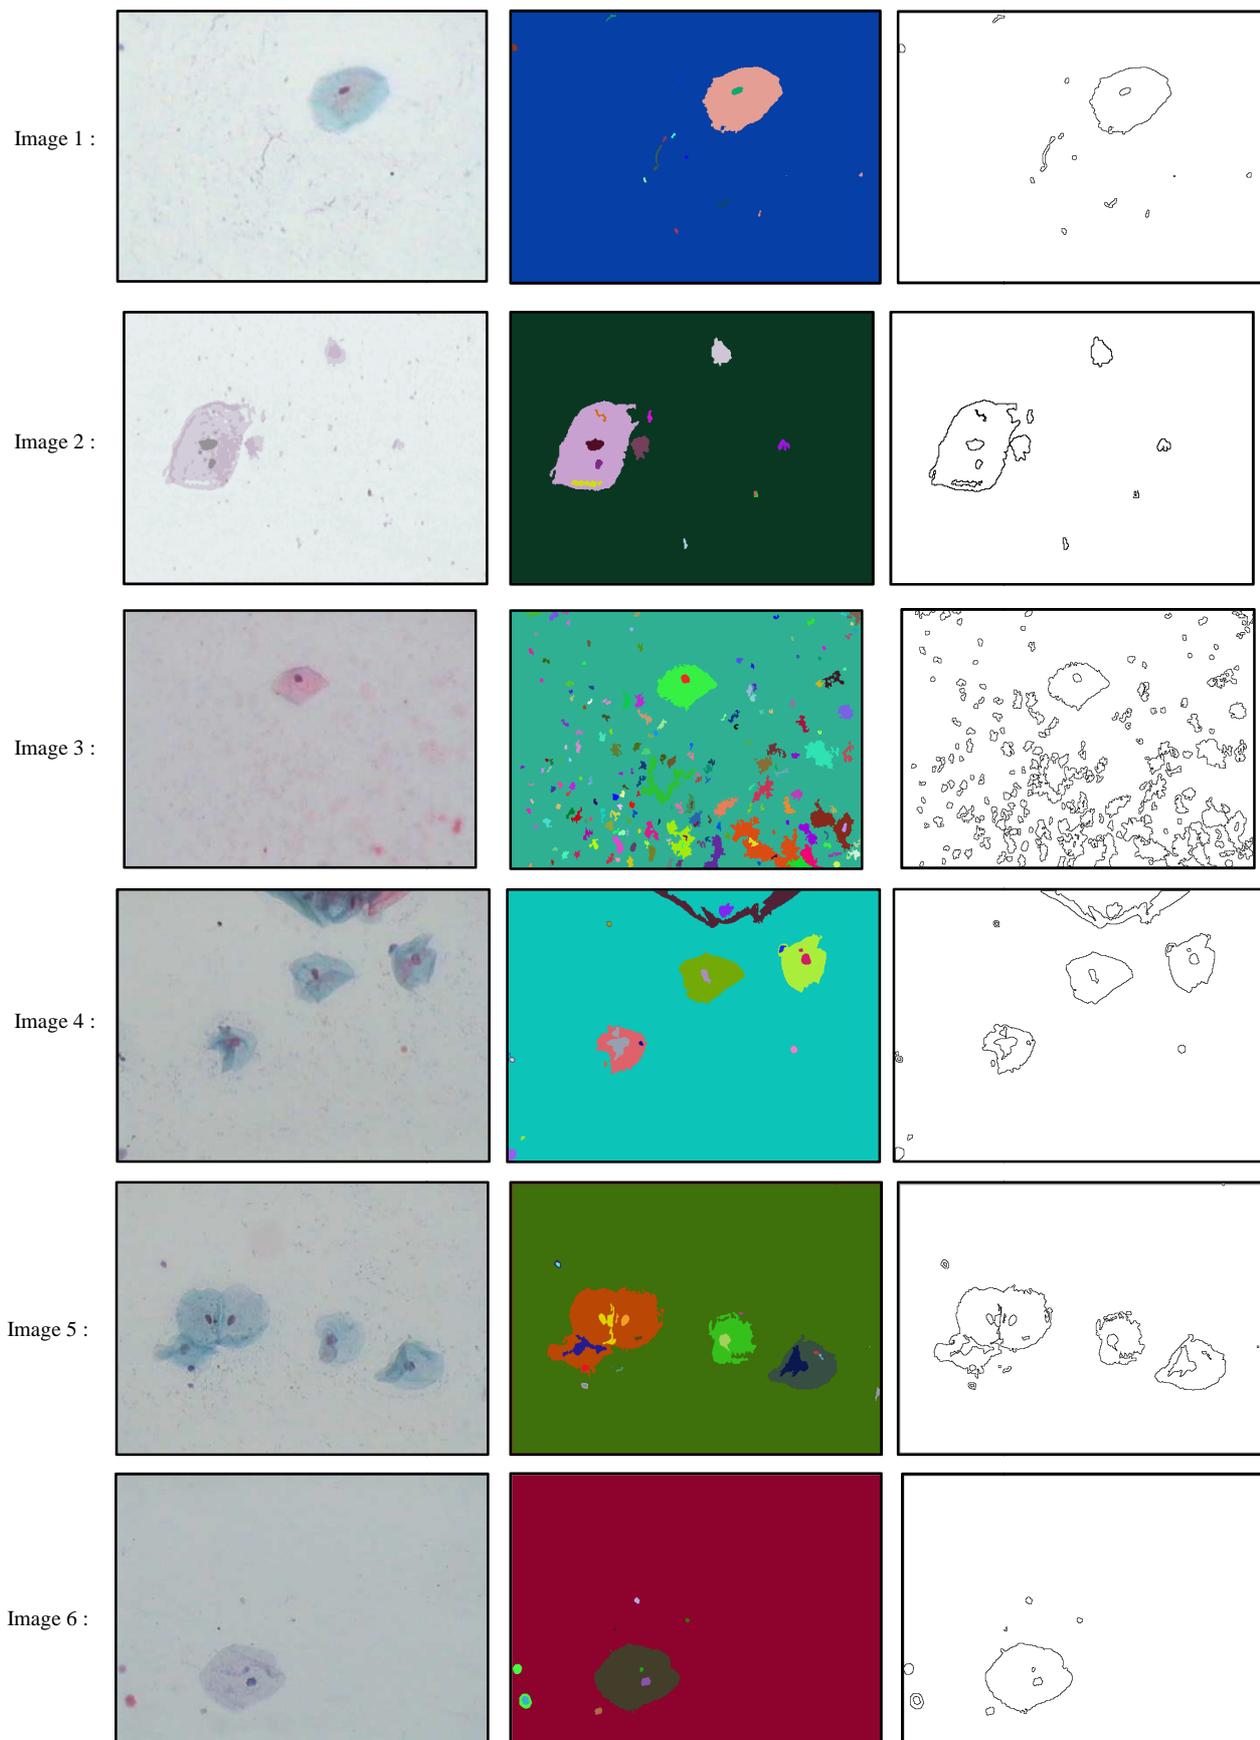


Fig 4.5. Résultats de l'application de la deuxième approche : exemples de la 1^{ière} à la 6^{ième} image.

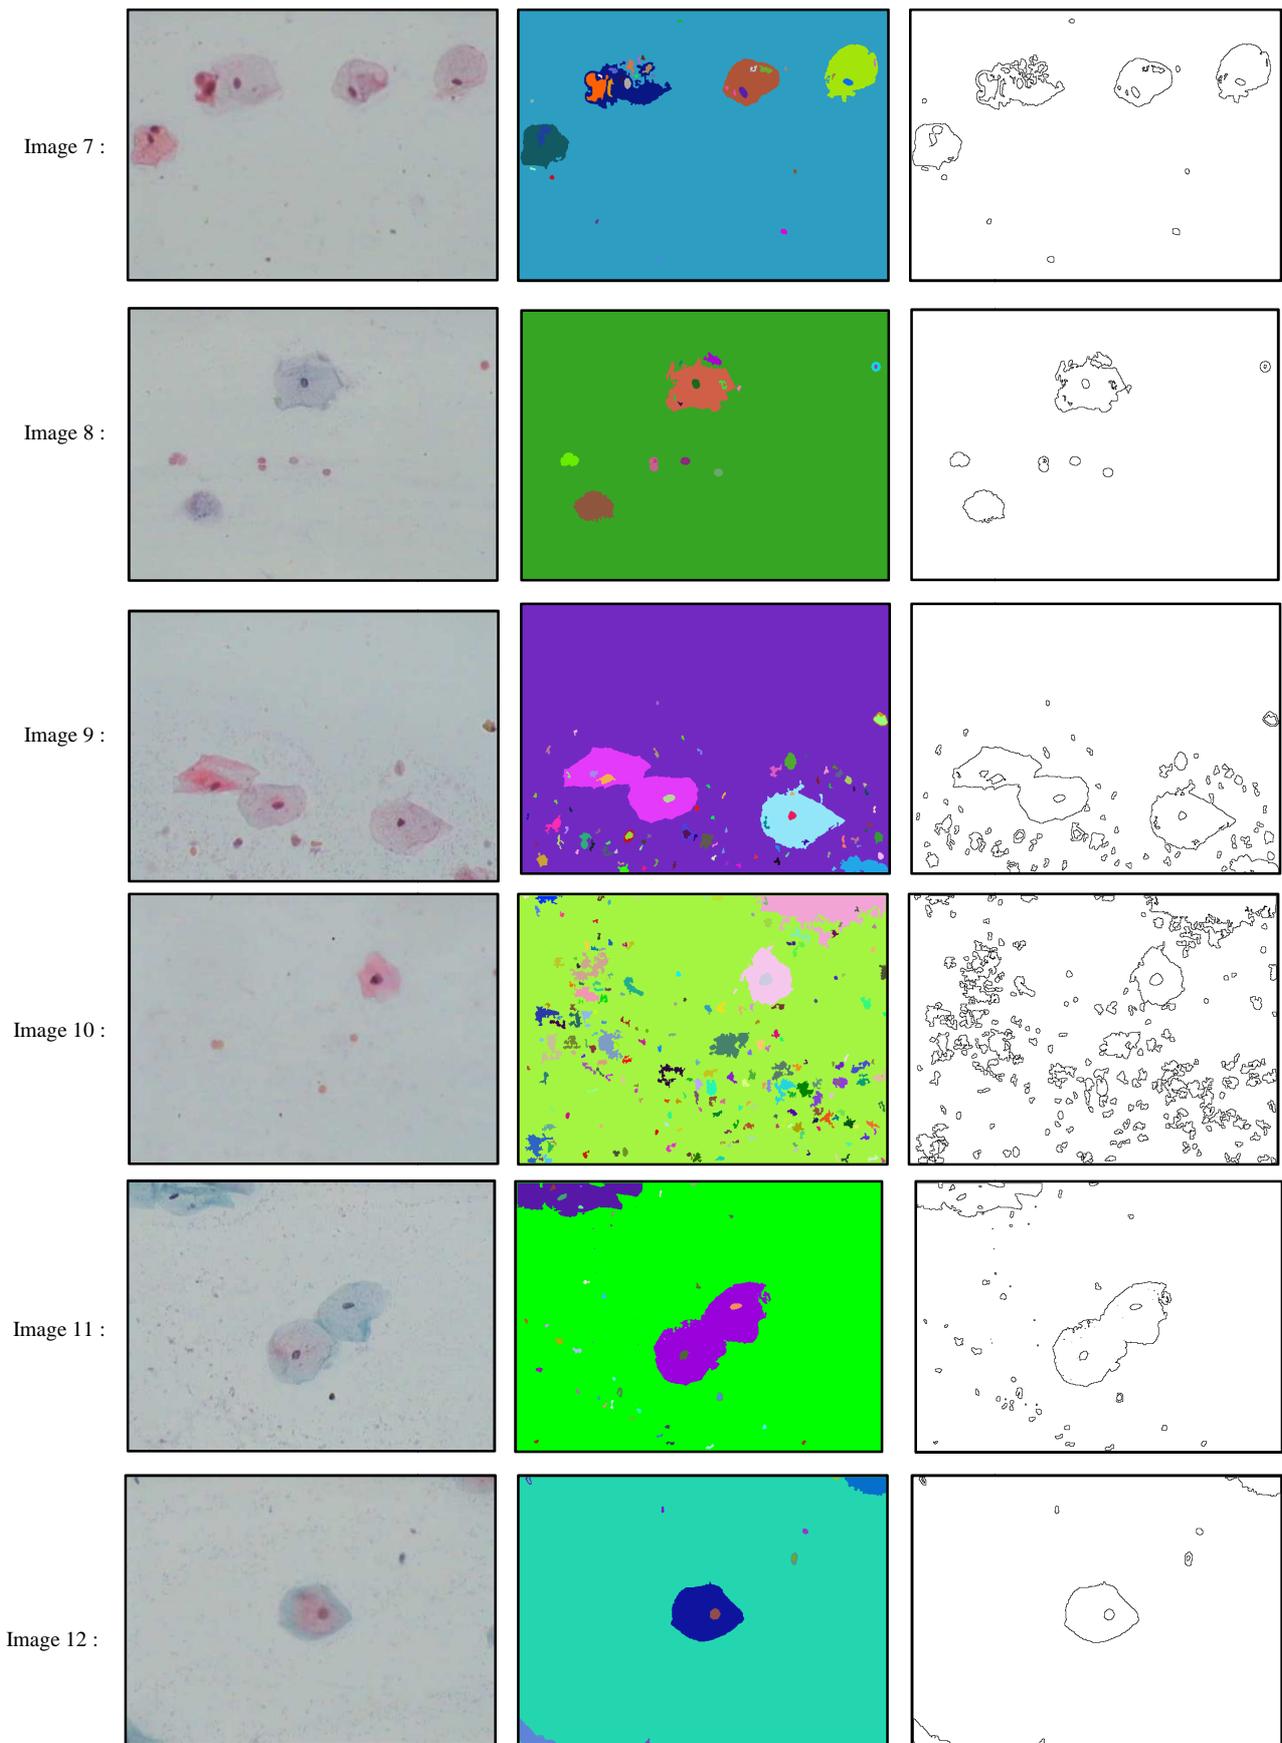


Fig 4.6. Résultats de l'application de la deuxième approche : exemples de la 7^{ème} à la 12^{ème} image.

4.3 Deuxième application : autres types d'images

Pour cette partie nous avons pris sept exemples d'images représentatifs, il s'agit de :

- Une image de Lena qui est une image de test standard, c'est une image couleur.
- Une image de Maison qui est aussi une image de test standard, mais c'est une image à niveaux de gris.
- Une image médicale *IRM*, c'est une image à niveaux de gris.
- Une image médicale de chromosomes couleur (une métaphase).
- Une image médicale d'angiographie coronaire, appelée aussi coronarographie.
- Une image d'ordre général qui est une image d'enfants, c'est une image couleur.
- Une image de peinture, nous avons pris l'image couleur de la Mona Lisa.

Les deux prochains paragraphes résument les résultats obtenus de l'application des deux approches sur les sept images.

4.3.1 Première approche

Les résultats du premier système automatique sont présentés sur les figures (Fig 4.7) et (Fig 4.8).

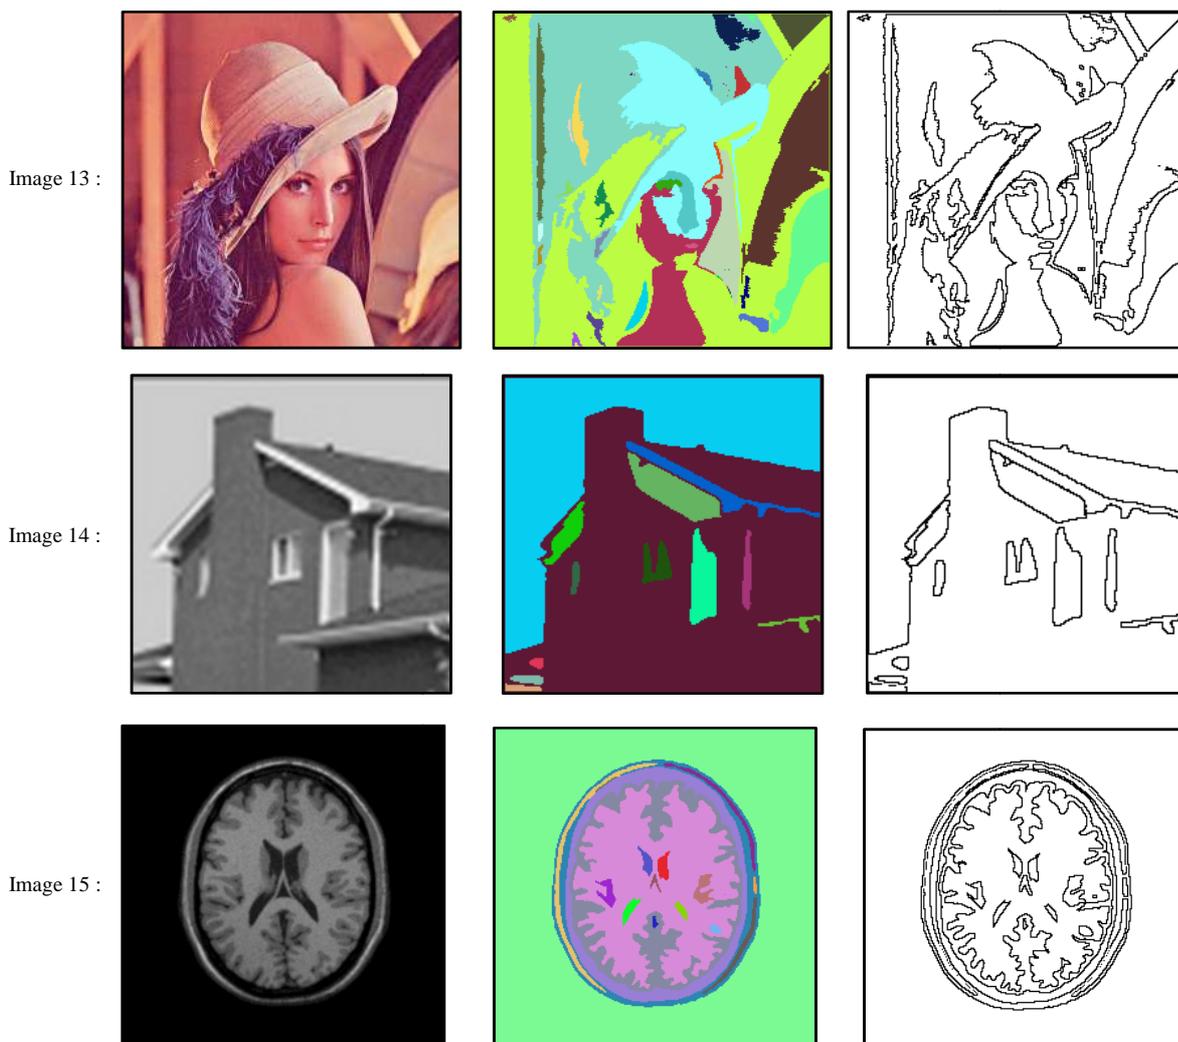


Fig 4.7. Résultats de l'application de la première approche : exemples de la 13^{ième} à la 15^{ième} image.

Image 16 :

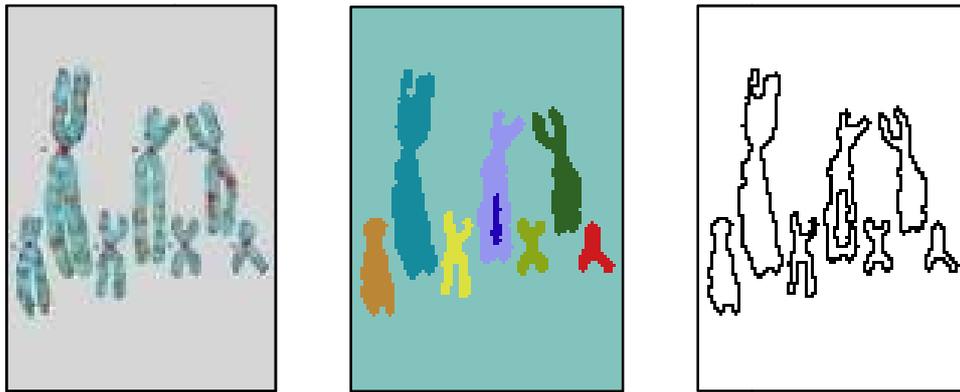


Image 17 :

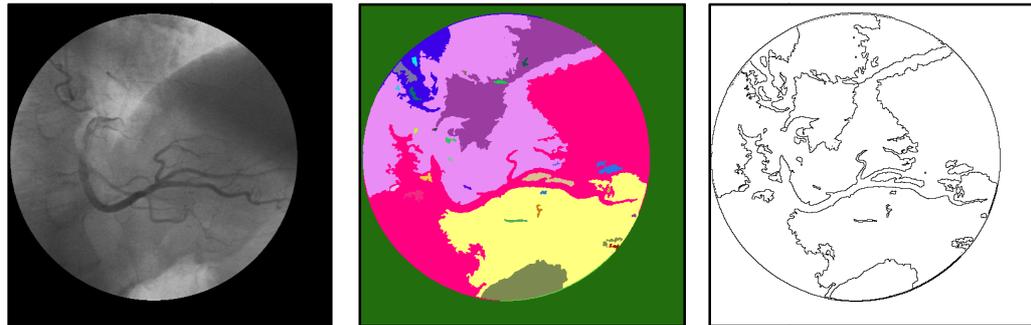


Image 18 :

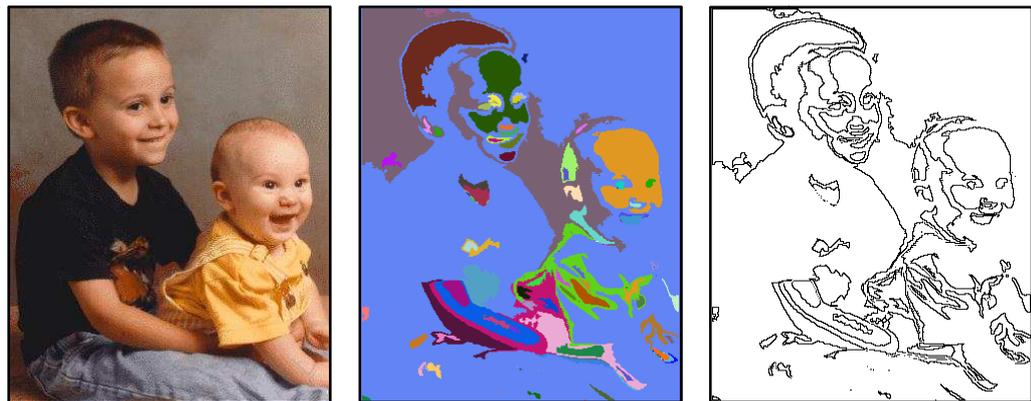


Image 19 :

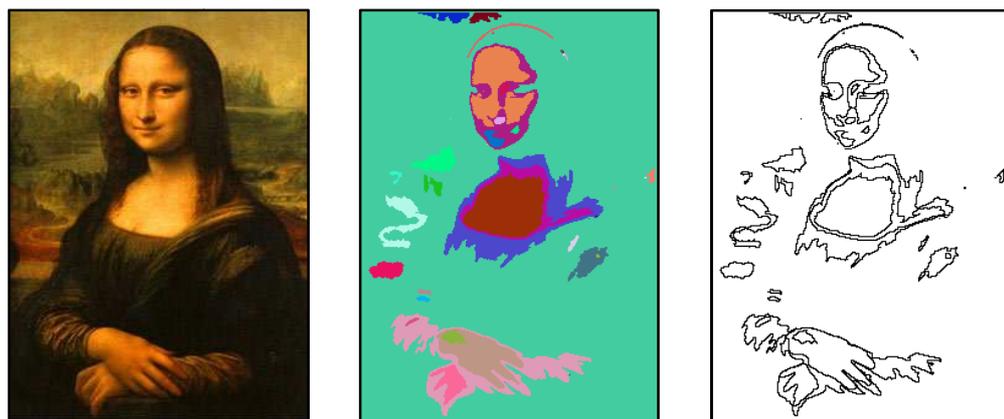


Fig 4.8. Résultats de l'application de la première approche : exemples de la 16^{ième} à la 19^{ième} image.

Qualifier le résultat de la segmentation pour ces différents types d'images est assez relatif au but de l'application de chacune des segmentations d'une part, et aussi de la qualité, du type et de la taille de l'image d'une autre part. Ceci demande évidemment l'avis de l'expérimenté du

domaine d'application ; mais a priori pour les deux images : l'image 14 et 15 de la figure (Fig 4.7) nous pouvons affirmer que les résultats sont bons ce qui n'est pas le cas pour les autres images. Il est clair que nous ne pouvons généraliser un seul système pour tout type d'image.

4.3.2 Deuxième approche

Les résultats du premier système automatique sont présentés sur les figures (Fig 4.7 Fig 4.9) et (Fig 4.10).

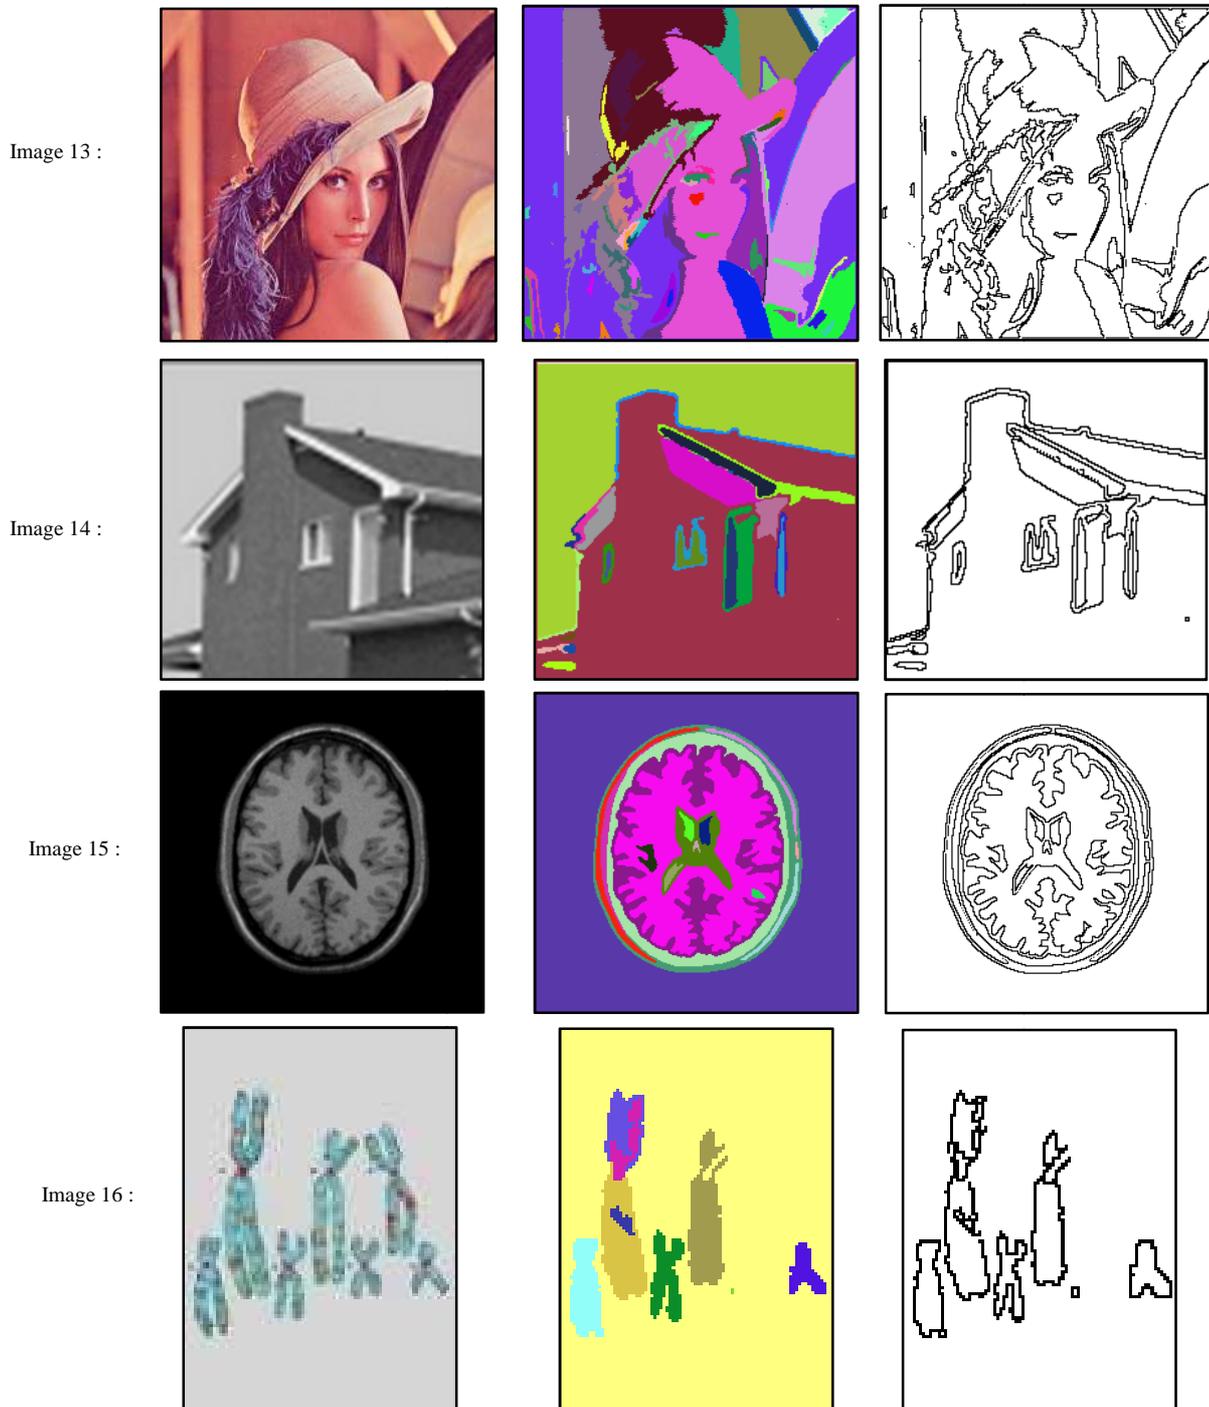


Fig 4.9. Résultats de l'application de la deuxième approche : exemples de la 13^{ième} à la 16^{ième} image.

Image 17 :

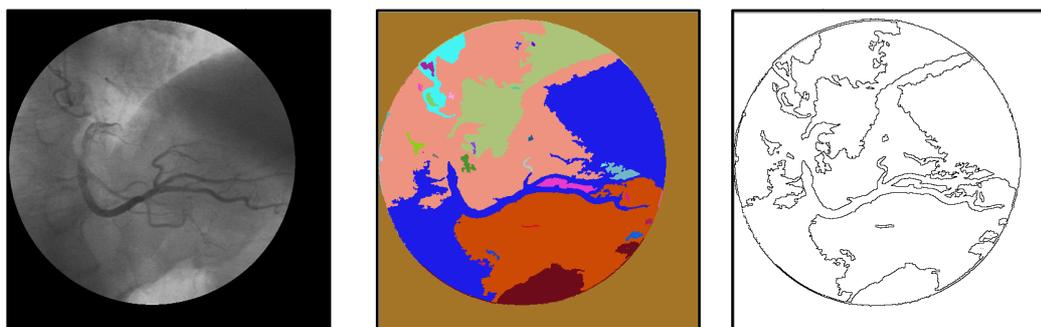


Image 18 :

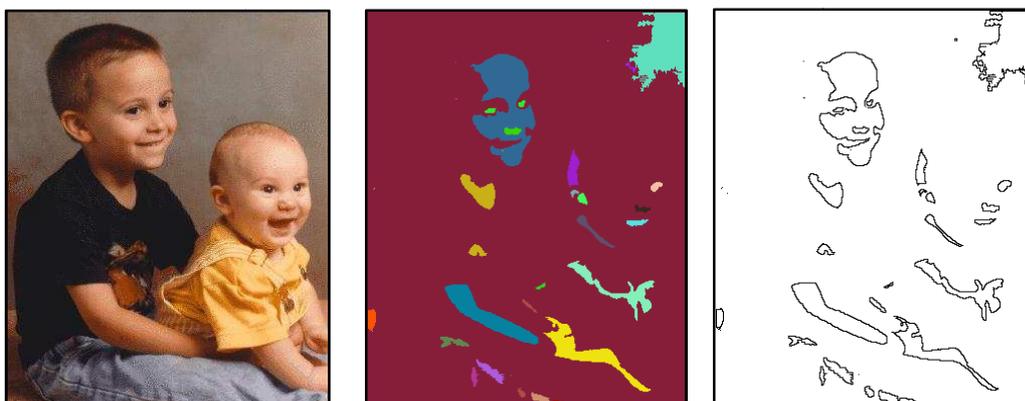


Image 19 :

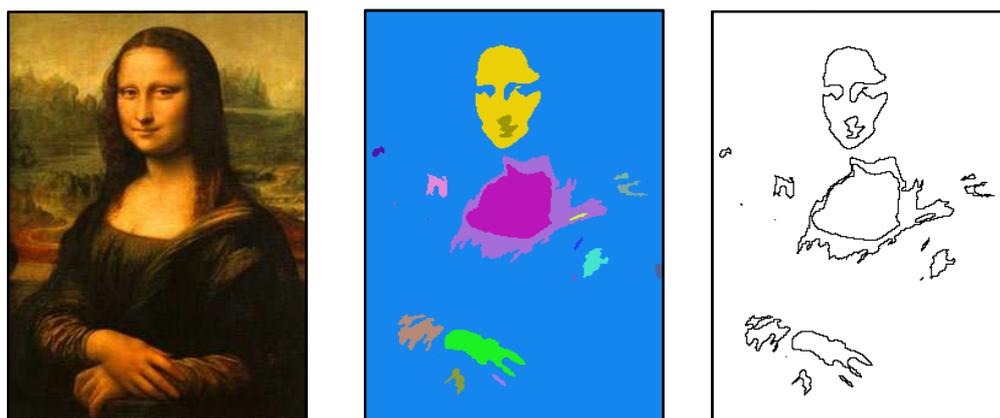


Fig 4.10. Résultats de l'application de la deuxième approche : exemples de la 17^{ième} à la 19^{ième} image.

Egalement pour cette deuxième approche les résultats sont relativement bons pour les deux images : image 'maison' et l'image *IRM* (image 14 et 15 de Fig 4.9).

Nous rappelons que notre méthode de segmentation s'appuie principalement sur l'attribut couleur et que la construction des deux systèmes a été basée sur des essais effectués sur des images cytologiques couleur. Il est évident que pour améliorer et généraliser les deux systèmes automatiques pour d'autres types d'image, une étude expérimentale est exigée.

4.4 Conclusion et commentaires

Nous avons appliqué nos deux systèmes automatiques sur plusieurs images de type cytologique et autre. La majorité des résultats obtenus sont assez bon, surtout en ce qui concerne le but de notre travail c'est-à-dire les images cytologiques. Cependant une amélioration de leur performance peut être apportée aux deux systèmes en faisant une étude approfondie sur tous les niveaux de construction de ces systèmes, c'est-à-dire : la méthode de segmentation, les critères d'évaluation, et le contrôleur flou pour de la deuxième approche.

Actuellement nous sommes en train de développer un logiciel qui englobe plusieurs tâches de traitement d'image, il s'agit de : la segmentation en régions et celle en contours que nous avons élaborées, l'évaluation des deux approches de segmentation et les deux systèmes de segmentation automatique.

Conclusion et Perspectives

De plus en plus le traitement d'images contribue de manière importante dans le diagnostic médical notamment dans le domaine anatomo-pathologique avec ses deux branches : histologie et cytologie. Dans ce mémoire nous nous sommes orientés vers l'étude des images cytologiques couleur dans le but d'alléger le travail du cytologiste qui consiste à détecter des anomalies éventuellement présentes dans les cellules analysées par le microscope.

C'est dans cette démarche que nous avons commencé par acquérir la vue de ces cellules sous formes d'images afin de pouvoir les analyser et les traiter par un programme de traitement d'images. Une fois que ces images ont été acquises nous avons pensé à les simplifier en images plus significatives et parlantes tout en gardant l'information qu'elles apportent. Pour ce faire nous avons appliqué une opération de segmentation qui consiste à faire le partage de l'image d'application pour repérer les objets qui sont principalement présents dans l'image cytologique, dans ce cas il s'agit du noyau et du cytoplasme de chacune des cellules présentes sur l'image.

La difficulté de cette opération réside dans le choix du type de segmentation, d'autant plus qu'il s'agit d'images couleur. Au début nous avons essayé de transformer ces images en images monochrome mais nous avons préféré garder l'information apportée par l'attribut couleur. Nous avons appliqué une segmentation en régions basée sur l'algorithme de classification Fuzzy-C-Means, que nous avons adapté pour recevoir en entrée l'image couleur, et sur l'algorithme d'étiquetage. Ces deux étapes constituent la segmentation en régions. Aussi nous avons appliqué une segmentation en contours faite à partir de l'image étiquetée.

Le résultat de la segmentation dépend des paramètres de la méthode appliquée. Pour des valeurs différentes de ces paramètres nous pouvons avoir une bonne ou une mauvaise segmentation. Donc il d'est avéré intéressant d'évaluer la qualité du résultat de la segmentation dans le but de la valider ou de la rejeter avant de la présenter au médecin cytologiste. Pour ce faire nous avons utilisé des critères d'évaluation dédiés pour la segmentation région et contour. Ces critères sont soit supervisés soit non supervisé. Les critères non supervisés se calculent à partir de l'image résultat de la segmentation. Quant aux critères non supervisés nécessitent une image de référence appelée vérité terrain afin de calculer l'écart entre les deux images et la convergence de l'image résultat vers la segmentation idéale.

L'évaluation de la segmentation nous permet de dire que le résultat d'une segmentation est bon ou mauvais. Cela nous a poussé à chercher le meilleur résultat que nous pouvons obtenir pour une méthode spécifique. Ce qui a donné l'idée d'automatiser la segmentation. Notre persévérance a abouti à concevoir deux systèmes automatiques. Le premier, travaillant en boucle ouverte, choisit parmi plusieurs segmentations établies la meilleure qui soit selon l'indication des critères d'évaluation sur la qualité de la segmentation. Ces critères d'évaluation sont aussi appelés critères de performance du système puisqu'ils mesurent la performance de l'algorithme de segmentation. Le deuxième système automatique corrige en boucle fermée et en temps réel le résultat de la segmentation, toujours selon l'indication des critères de performance en agissant sur les paramètres d'action. Il est basé sur la commande floue, une nouvelle théorie de contrôle qui s'est montrée assez fiable dans la discipline automatique.

La couleur étant un attribut important présent dans l'image couleur, nous avons essayé d'utiliser différentes manières pour exploiter l'information apportée par cet attribut. Notons que le long de notre travail nous avons appliqué nos approches dans l'espace couleur RVB ainsi que dans d'autres types d'espace couleur. Cependant l'interprétation du comportement des critères d'évaluation de la segmentation calculés dans ces derniers espaces couleur, a été difficile à concevoir ce qui n'a pas donné suite à cette démarche.

Finalement, nous avons testé notre méthode sur plusieurs images cytologiques et aussi sur d'autres types d'images. Les résultats ont été satisfaisants dans l'ensemble. Et nous proposons comme perspectives l'utilisation d'autres critères d'évaluation, d'approfondir l'étude des différents critères appliqués sur d'autres types d'espace couleur, de définir de façon crédible une image vérité terrain (image référence) car elle influence considérablement le calcul des critères d'évaluation supervisée, de diminuer le temps de calcul et d'enrichir l'information sur plus d'images tests afin de rendre les deux systèmes conçus plus fiables. Notre principale perspective est de concevoir un logiciel qui assure une interface englobant tout le traitement établi, c'est-à-dire : segmentation, évaluation et conception des deux systèmes automatiques. Ce travail est entamé et se poursuit positivement.

En résumé le travail de ce mémoire propose :

- Une méthode de segmentation en régions assez fiable.
- Une méthode de segmentation en contours très cohérente.
- Des critères d'évaluations de segmentation pour une approche région et pour une approche contour.
- Deux systèmes de segmentation automatique.

Ainsi il offre au cytologiste la meilleure segmentation d'une image cytologique. Grâce à cette segmentation son travail de diagnostic et de prise de décision (qui peut aussi être automatisé) devient moins lourd, plus précis et relativement plus rapide.

Bibliographie

- [1] R. C. Gonzalez et P. Wintz, Digital Image Processing, édition Addison Wesley, 1987.
- [2] J.P. Cocquerez, S. Philipp et al. , Analyse d'images : filtrage et segmentation, édition Masson, 1995.
- [3] A. Trémau et al. , Image numérique couleur, édition Dunod, 2004.
- [4] R. Sève, Physique de la couleur, Masson, Physique fondamentale et appliquée, 1996.
- [5] http://www-cal.univ-lille1.fr/~ag/enseigne/image/seance1_2.html.
- [6] http://www.chin.gc.ca/Francais/Contenu_Numerique/Numerisez_Collections/Subsections/numeriques_analogiques.html.
- [7] <http://laphotonumerique.free.fr>.
- [8] http://www710.univ-lyon1.fr/~fdenis/club_EEA/cours/couleur2.html
- [9] M. Kunt, Traitement numérique des images, traitement de l'information : volume 2, édition Presses Polytechniques et Universitaire Romandes 1993.
- [10] A. Renouf, R. Clouard et M. Revenu, A formulation model for image processing applications, GRETSI, Traitement du Signal, Vol. 24, N° 5, pp. 337-352, 2007.
- [11] R. Kouassi, J. Devaux, et P. Gouton, Etude comparative des propriétés de décorrelation et de représentation des images couleur dans l'espace RVB, TLS et ses dérivées, pp. 171-177, 1997.
- [12] K.S. Deshmukh et G.N. Shinde, An adaptative color image segmentation, Electronic letters on computer vision and image analysis 5(4), pp. 12-23, 2005.
- [13] J.P. Cocquerez et J. Devars, Détection de contours dans les images aériennes : nouveaux opérateurs (Edge detection in aerial pictures: new operators), Traitement du signal, volume 2 -n°1, pp. 45-65, 1985.
- [14] T. Carron, Segmentation d'images couleur dans la base Teinte Luminance Saturation : approche numérique et symbolique, Thèse de doctorat Université de Savoie, 1995.
- [15] Samuel Drulhe et Martial Hue, Segmentation des images couleurs : méthode d'Ohlander, Price et Reddy, Telecom Paris, 2004.
- [16] Y.R. Huang et al., Integrating Region Distribution and Edge Detection for Color Image Segmentation, Int. Computer Symposium, pp. 777-782, 2004.

- [17] P. Bauer, E. Klement et al. , Fuzzy Systems in computer science : Chapitre interpolation and approximation of real input-output functions using fuzzy rule bases, pages 245-254, édition Braunschweig, 1994.
- [18] Bezdek, Pattern Recognition with Fuzzy Objective Function Algorithms, Plenum Press, New York 1981.
- [19] <http://fleche.org/pierre/logfloue>.
- [20] H. Zang, J.E. Fritts, S.A. Goldman, A co-evaluation framework for improving segmentation evaluation, SPIE Defense and Security Symposium-Signal Processing Sensor Fusion, and Target Recognition, XIV, pp. 420-430, 2005.
- [21] S. Cahbrier, Contribution à l'évaluation de performances en segmentation d'images, thèse de doctorat, université d'Orléan, décembre 2005.
- [22] E. Baudrier, G. Millon, F. Nicolier, S. Ruan, Binary-image comparison with local-dissimilarity quantification, Pattern Recognition, Vol 41, n°5, pp. 1461-1478, mai 2008.
- [23] R. A. Peters, R. N. Strickland, Image Complexity Metrics for Automatic Target Recognizers, Automatic Target Recognizer System and Technology Conference, Silver Spring, MD, 1990.
- [24] A. de Oliveira, H. Sok Ai et K. Ghellam, Distance de Hausdorff et application dan les IFS, Congrès "MATH.en.JEANS", pp. 85-90, mai 1994.
- [25] P. S. Liao, T. S. Chen et P. C. Chung, A Fast Algorithm for Multilevel thresholding, Journal of Information Science and Engineering 17, pp. 713-727, 2001.
- [26] J. Fan, X. Zhu et L. Wu, Automatic Model-Based Semantic Object Extraction Algorithm, IEEE Transactions on circuits and systems for video technology, vol. 11, no. 10, pp. 1073-1084, october 2001.
- [27] S. Albayrak, F. Amasyali, Fuzzy C-Means clustering on medical diagnostic systems, International XII. Turkish Symposium on Artificial Intelligence and Neural Networks – TAINN, 2003.
- [28] H. Grecu, P. Lambert, Image Retrieval by Partial Queries, Proc. of the 8th IEEE International Conference on Image Processing (ICIP'01), Thessaloniki, Greece, pp. 26-29, Oct. 2001.
- [29] P. Lambert, H. Grecu, A quick and coarse color image segmentation, ICIP, 14-17 Septembre, 2003.