



RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET  
POPULAIRE  
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA  
RECHERCHE SCIENTIFIQUE  
UNIVERSITÉ ABOU BEKR BELKAID TLEMCEEN  
FACULTÉ DE TECHNOLOGIE  
LABORATOIRE DE RECHERCHE EN GÉNIE BIOMÉDICAL

# THÈSE

Pour obtenir le titre de Docteur, spécialité  
« Génie Biomédicale »

Présentée par

Touria BAAKEK

---

## SEGMENTATION ET CLASSIFICATION INTÉLLIGENTE DES IMAGES CÉRÉBRALES (IDENTIFICATION DE TUMEURS)

---

Thèse soutenue en 25 Juin 2015 devant le jury :

M.HADJ SLIMANE Zine Eddine	PR.UABT Tlemcen	Président
M.CHIKH Mohamed Amine	PR. UABT Tlemcen	Directeur de thèse
M. BELALEM Ghalem	PR. Université Oran	Examineur
M <sup>me</sup> HAMDADOU Djamila	MCA. Université Oran	Examineur



*Soyons reconnaissants aux personnes qui nous donnent du bonheur ; elles sont les charmants jardiniers par qui nos âmes sont fleuries.*

***Marcel Proust***

# REMERCIEMENTS

Au terme de ce travail, c'est avec émotion que je tiens à remercier tous ceux qui, de près ou de loin, ont contribué à la réalisation de ce projet.

Je tiens tout d'abord à exprimer mes plus sincères remerciements et ma profonde reconnaissance envers mon directeur de thèse Monsieur CHIKH Mohamed Amine pour sa patience, sa disponibilité malgré ses nombreuses charges et le soutien constant et la confiance qu'il m'a toujours accordée. Je le remercie chaleureusement pour ses conseils et pour m'avoir suivi et orienté tout au long de ces longues années.

Je tiens particulièrement à le remercier de la liberté d'action qu'il m'a donné à chaque étape de cette aventure. J'espère avoir été digne de la confiance qu'il m'avait accordé et que ce travail est finalement à la hauteur de ses espérances. Quoi qu'il en soit, j'ai beaucoup appris à ses côtés et je suis très honorée de l'avoir eu pour encadrant.

Je remercie vivement Monsieur HADJ SLIMANE Zine Eddine professeur à l'université de Tlemcen qui nous a fait l'honneur de présider le jury.

Je remercie chaleureusement Madame D. HAMDADOU maître de conférences à l'université d'Oran, Monsieur G. BELALEM professeur à l'université d'Oran pour l'intérêt qu'ils ont bien voulu porter à ce travail en acceptant de l'examiner et d'en être rapporteurs et pour le temps consacré à la lecture de cette thèse.

Une mention spéciale pour BAAKEK Yettou Nour El Houda maître de conférences à l'université de Tlemcen, cette thèse n'aurait pas vu le jour sans son soutien inconditionnel.

Je tiens également à remercier monsieur BECHAR Mohamed Amine membre du laboratoire génie biomédical pour son aide précieuse.

A :

*Mes parents*

*Mon mari*

*Mes frères et sœurs*

**Résumé :**

Les tumeurs cérébrales constituent un champ d'application privilégié pour les techniques d'irradiation basées sur l'imagerie médicale. La segmentation de ces images est l'objectif principal de ce travail où nous avons proposé une nouvelle méthode hybride pour la segmentation des images cérébrales.

Pour se faire nous adoptons une combinaison entre le seuillage itératif ISODATA et l'algorithme standard Graph cuts. Cette approche hybride donne des résultats prometteurs qui ne dépendent pas du fameux paramètre  $\lambda$ .

L'évaluation de la méthode proposée est effectuée par une comparaison des résultats obtenus avec d'autres images issues principalement de la base de données IMAIOS qui offre des informations et des détails suffisants fournis par des médecins pour valider notre algorithme. Une partie de classification a été réalisée à la fin de ce travail pour montrer l'intérêt de l'approche adoptée.

**Mots clés :** lésion cérébrale, segmentation, approche hybride, ISODATA, Graph cuts, classification.

**Abstract:**

Brain tumors are a scope for favors irradiation techniques based on medical imaging. The segmentation of these images is the objective of this work while designing a new hybrid method for brain images segmentation.

To do this we adopt a combination of iterative thresholding or multi-level thresholding ISODATA and Graph cuts standard algorithm. This hybrid approach shows promising results which do not depend on the parameter  $\lambda$ .

The evaluation of the proposed method is performed by comparing the obtained results with other images coming mainly from the database IMAIOS, which offers sufficient information and details provided by doctors to validate our algorithm.

A classification part has been added to this work in order to show the importance of the proposed segmentation algorithm.

**Key words:** brain tumors, segmentation, hybrid approach, ISODATA, Graph cuts, classification.

## ملخص

تقسيم صور الاورام الدماغية الناتجة عن تقنيات التصوير الطبية مثل التصوير بالرنين المغناطيسي يعد الهدف الرئيسي لهذه الدراسة. لهذا السبب قمنا بتطوير طريقة هجينة جديدة مكونة من طريقة العتبة المتكررة وتقطيع الرسم البياني.

هذه الطريقة الهجينة اعطتنا نتائج جد مرضية وغير مرتبطة بالمعامل  $\lambda$

قمنا بتقييم الطريقة المقترحة بعد مقارنة النتائج المتحصل عليها مع صور اخرى مأخوذة من قاعدة بيانات IMAIOS التي تعطينا معلومات مهمة عن الاورام الدماغية وتشخيصها .

كلمات مفتاحية: أورام دماغية ، تقسيم الصور ، طريقة هجينة ، العتبة المتكررة، تقطيع الرسم البياني.

## Table des matières

INTRODUCTION GENERALE.....	1
LES TUMEURS CEREBRALES.....	5
1. INTRODUCTION.....	5
2. ANATOMIE DU CERVEAU.....	6
2.1. L'ENCEPHALE.....	7
2.2. SUBSTANCE GRISE ET BLANCHE.....	7
2.3. ELEMENTS CELLULAIRES DU SYSTEME NERVEUX.....	8
2.3.1. LE NEURONE.....	8
2.3.2. LES CELLULES GLIALES.....	8
2.3.3. LES CELLULES EPENDYMAIRES.....	9
2.4. LES LOBES CEREBRAUX.....	9
3. CLASSIFICATION DES TUMEURS CÉRÉBRALES.....	9
3.1. CLASSIFICATION SUIVANT L'HISTOLOGIE.....	10
4. PRINCIPALES TUMEURS CEREBRALES PRIMITIVES.....	11
4.1. ASTROCYTOMES.....	12
4.2. GLIOBLASTOME.....	13
4.3. OLIGODENDROGLIOME.....	14
4.4. EPENDYMOMES.....	15
4.5. LYMPHOME PRIMITIF CEREBRAL.....	16
4.6. MENINGIOMES.....	17
4.7. NEURINOME DE L'ACCOUSTIQUE.....	18
4.8. KYSTES DERMOÏDES ET EPIDERMOÏDES.....	19
4.9. HEMANGIOBLASTOMES.....	20
4.10. ADENOMES HYOPHYSAIRES.....	21
5. CONCLUSION.....	22
APPROCHES DE SEGMENTATION D'IMAGES.....	23
(ÉTAT DE L'ART).....	23
1. INTRODUCTION.....	23
2. L'HISTOGRAMME.....	23



3. APPROCHES DE SEUILLAGE POUR LA SEGMENTATION DE L'IMAGE.....	26
3.1. LES METHODES GLOBALES .....	26
3.1.1 METHODE D'OTSU ET SES DERIVES .....	27
3.1.2. METHODES BASEES SUR LE PRINCIPE DE L'ENTROPIE .....	30
3.1.3. METHODES BASEE SUR L'HISTOGRAMME CONVEXE.....	35
3.1.4. LE SEUILLAGE PAR L'APPROCHE DE CLASSIFICATION.....	36
3.2. LES METHODES LOCALES.....	36
4. APPROCHES DE SEGMENTATION BASEES SUR LE GRAPH CUT .....	38
5. CONCLUSION .....	42
COUPE DE GRAPHE (GRAPH CUTS) ET SEUILLAGE ITÉRATIF (ISODATA) POUR LA SEGMENTATION D'IMAGE. ....	43
1. INTRODUCTION.....	43
2. L'ALGORITHME GRAPH CUT.....	44
2.1. DEFINITION .....	44
2.2. GRAPHE NON ORIENTE .....	44
2.3. GRAPHE ORIENTE .....	45
2.4. GRAPHE VALUE.....	46
2.5. LE VOISINAGE .....	47
2.6. FLOT MAXIMUM.....	47
2.7. COUPE DE GRAPHE.....	50
2.8. THEOREME DE MAX FLOW/MIN CUT .....	52
2.9. LES COUPES DE GRAPHE NORMALISEES.....	52
2.10. SEGMENTATION D'IMAGE PAR GRAPH CUT .....	53
3. L'ALGORITHME ISODATA .....	56
3.1. LE SUIILLAGE .....	57
3.2. SEGMENTATION D'IMAGE PAR CLASSIFICATION .....	57
4. CONCLUSION .....	61
SEGMENTATION INTERACTIVE D'IMAGES CÉRÉBRALES EN COMBINANT LE SEUILLAGE AUTOMATIQUE ET LA COUPE DES GRAPHE.....	62

1. INTRODUCTION.....	62
2. ALGORITHME HYBRIDE .....	64
2.1. ALGORITHME ISODATA.....	64
2.2. L'ALGORITHME GRAPH CUT.....	66
3. CONCLUSION .....	80
CARACTÉRISATION ET CLASSIFICATION DES TUMEURS CEREBRALES .....	81
1. INTRODUCTION.....	81
2. REDUCTION DE DIMENSIONS .....	81
3. EXTRACTION DES ATTRIBUTS.....	83
4. LES DIFFERENTS TYPES D'APPRENTISSAGE.....	86
4.1. APPRENTISSAGE SUPERVISE.....	86
4.2. APPRENTISSAGE NON SUPERVISE.....	86
4.3. APPRENTISSAGE PAR RENFORCEMENT .....	86
5. CLASSIFICATION DES IMAGES CEREBRALES .....	87
6. BASES DE DONNEES .....	91
7. EVALUATION DE L'ALGORITHME DE SEGMENTATION.....	92
8. CONCLUSION .....	101
CONCLUSION GENERALE ET PERSPECTIVES.....	103
REFERENCE.....	106

# Table des figures

Figure 1.1 : Anatomie du cerveau. ....	6
Figure 1.2 : L'encéphale .....	7
Figure 1.3 : Substance blanche et grise .....	7
Figure 1.4 : Neurone .....	8
Figure 1.5 : Les lobes externes du cerveau humain .....	9
Figure 1.6 : Siège des néoplasies les plus courantes .....	12
Figure 1.7 : Astrocytome kystique du cervelet .....	13
Figure 1.8 : Glioblastome multiforme .....	14
Figure 1.9 : Oligodendrogliome IRM du cerveau .....	15
Figure 1.10 : Ependymome .....	15
Figure 1.11: Lymphome. ....	16
Figure 1.12 : Lymphome .....	17
Figure 1.13 : Tomodensitométrie axiale du cerveau. ....	17
Figure 1.14 : Structure d'un neurone .....	18
Figure 1.15 : Nerinome de l'acoustique. ....	19
Figure 1.6 : Epidermoïde. ....	19
Figure 1.17 : Kyste dermoïdecérébelleu. ....	20
Figure 1.18 : Hémangioblastome cérébelleux .....	20
Figure 1.19: Hémangioblastome cérébelleux. ....	21
Figure 2.1 : Exemple d'histogramme .....	24
Figure 2.2 : Histogramme unimodal. ....	24
Figure 2.3 : Histogramme bimodal. ....	25
Figure 2.4 : Histogramme multimodal. ....	25
Figure 3.1 : Exemple d'un graphe .....	44
Figure 3.2 : graphe non orienté .....	45
Figure 3.3 : graphe orienté. ....	45
Figure 3.4 : multi graphe .....	46
Figure 3.5 : exemple de source S et puits T. ....	46
Figure 3.6 : Graphe valué. ....	47
Figure 3.7: Coupe de graphe. ....	51
Figure 3.8: Exemple de coupe de graphe .....	51
Figure 3.9: exemple seuillage ISODATA (classification). ....	60
Figure 4.1: coupe de graphe min cut sur une image de 3x4. ....	67
Figure 4.2 : Répartition des niveaux de gris des pixels selon la classe objet ou la classe fond. ....	68

Figure 4.3: segmentation d'images en appliquant l'algorithme de Graph cuts. .....	74
Figure 4.4 : segmentation d'images en appliquant l'algorithme de Graph cuts. .....	75
Figure 4.5 : Segmentation d'image en appliquant l'approche hybride.....	76
Figure 4.6: Comparaison de segmentation d'une image à faible contraste.....	78
Figure 4.7: Exemple de la limite de l'algorithme.....	79
Figure.5.1 : Définition des couches d'un réseau multicouche. ....	88
Figure .5.2 : Hyper plan et vecteur support.....	90
Figure.5.3 : SVM linéaire et non linéaire.....	91
Figure.5.4 : Exemples de segmentation des images cérébrales avec faible contraste de la base de données IMAIOS en utilisant notre approche.....	97
Figure.5.5 : Exemples de faux positifs.....	99
Figure.5.6 : Volumineux méningiome.....	100



# Liste des tableaux

Tableau 1.1 : principales classes de tumeurs cérébrales primitives.....	11
Tableau 4.1 : Comparaison des résultats de segmentation.....	77
Tableau 5.1 : Mesure des performances obtenues par les classifieurs PMC, SVM et KNN.....	95
Tableau 5.2 : Comparaison du taux de classification.....	98
Tableau 5.3 : Comparaison de mesures de performances de notre algorithme avec l'algorithme de Boykov et Jolly et approche de Bricq.....	100

# Liste des abréviations

Graph cuts : Coupe de graphe.

ISODATA : Iterative Self Organizing Data Analysis Technique.

IRM : imagerie par résonance magnétique.

BrainWeb : Base de données

(<http://brainweb.bic.mni.mcgill.ca/brainweb/>).

IMAIOS : Base de données (<https://www.imaios.com/fr>).

IMADIS : base de données (<https://www.imadiss.com/fr>).

Min cut : coupe minimale.

Max flow : le flot maximum.

Svm : machine à vecteur support.

KNN : le K plus proche voisins.

RN : réseau de neurone.

PMC : perceptron multi couche.

# INTRODUCTION GENERALE

## 1. Contexte et problématique

La segmentation d'images dans un contexte clinique reste une problématique majeure de l'imagerie médicale. C'est une tâche critique qui nécessite beaucoup d'effort et qui conditionne la qualité des traitements d'images effectués ultérieurement, elle permet d'isoler les zones d'intérêts dans une image sur lesquels doit porter l'analyse future.

Le diagnostic médical devient de plus en plus fiable grâce au développement des techniques modernes et sophistiquées d'acquisition. Elles permettent une reconnaissance crédible des pathologies avec un taux d'erreur réduit. Ils existent plusieurs méthodes de segmentation d'images dans la littérature qui donnent l'embarra du choix, et c'est un débat qui fait rage pour les utilisateurs.

Les travaux de recherche dans la littérature confirment l'inexistence d'une seule méthode de segmentation qui peut s'adapter à une variété d'image et qui peut donner des résultats optimaux. Le résultat de la segmentation influence beaucoup sur la forme de l'objet et sur la qualité de l'image. La majorité des méthodes de segmentation offre des résultats selon le type et la qualité de l'image (en niveau de gris, en couleur, le moyen d'acquisition...etc.).

La qualité des résultats de segmentation basés sur l'approche de Boykov et Jolly (2001), en utilisant l'algorithme min cut/max flow, dépend essentiellement du choix de la valeur du paramètre  $\lambda$ . C'est un paramètre réel positif qui fait partie de l'expression de minimisation de l'énergie dans le but de segmenter l'image et séparer la tumeur du reste de l'image cérébrale.

Le recherche de la valeur optimale de  $\lambda$  pour chaque image consomme énormément de temps, et par conséquent ça devient une contrainte de



temps en passant d'une valeur à l'autre pour trouver la bonne valeur de  $\lambda$  qui correspond à chaque image.

La segmentation des images médicales et notamment les images cérébrales qui contiennent des tumeurs est une tâche compliquée. En effet le faible contraste des images constitue un handicap majeur de segmentation, parce que nous pouvons tomber sur une forte ressemblance en niveaux de gris entre la lésion elle-même et les vaisseaux sanguins, les cellules gliales, la matière grise ou bien la substance blanche par exemple, ce qui rend la mission de segmenter la tumeur cérébrale difficile.

La classification des données dépend énormément de la phase de segmentation. Beaucoup de classifieurs échouent faute de vecteur de caractéristiques pertinentes.

Pour répondre aux contraintes citées ci-dessus, dans cette thèse nous avons construit une méthode hybride de segmentation basée sur la combinaison de deux méthodes Graph cuts basée sur le principe de minimisation de l'énergie, et le seuillage itératif, connu sous le nom ISODATA.

La combinaison des deux méthodes nous a permis de donner des résultats prometteurs. En effet, le seuillage itératif ISODATA est une méthode de classification non supervisée, qui permet d'effectuer une très bonne catégorisation et il peut être traité comme une cible de qualité à atteindre, il permet notamment une pré-segmentation de l'image et donc mettre en évidence les zones d'intérêts qui est la tumeur cérébrale dans notre cas. Ce choix est motivé par la simplicité de cet algorithme tout en permettant une bonne segmentation de l'image dont l'histogramme n'est pas unimodal.

Les approches de la théorie des graphes (graph cuts) sont basées généralement sur le principe de minimisation de l'énergie. Le graph cuts permet la segmentation finale de l'image. Les récentes recherches en imagerie médicale ont montré leurs avantages et leurs qualités en termes de segmentation interactive.

En combinant ces approches, le problème du choix optimal de la valeur de  $\lambda$  disparaît complètement, par conséquent ça permet un gain très important de temps. La qualité de segmentation est nettement meilleure par rapport à l'algorithme standard de Graph cuts avec un lissage très correct des bordures de la tumeur segmentée.

Notre approche hybride permet aussi une très bonne segmentation de la tumeur cérébrale dans le cas où les images sont faiblement contrastées.

Dans le domaine médical, le médecin est le meilleur classifieur. La bonne caractérisation permet une bonne classification. Nous avons extrait des caractéristiques artificielles dans le but de classifier les images et évaluer les résultats obtenus en appliquant l'algorithme hybride.

## 2. Organisation de la thèse

Ce document est divisé en deux parties. La première partie présente l'anatomie du cerveau et une représentation des tumeurs cérébrales et leur classification selon le degré de malignité apporté par l'organisation mondiale de la santé (OMS) qui est présentée dans le premier chapitre.

La deuxième partie de notre travail est bien évidemment technique, qui réside essentiellement dans la présentation des deux méthodes de segmentation, l'approche de classification basée sur un algorithme de classification ISODATA, et la segmentation interactive basée sur la théorie des graphes.

Le deuxième chapitre est consacré à l'état de l'art, en citant et décrivant les principales méthodes existantes pour le seuillage des images et pour la théorie des graphes puisqu'elles sont la base de notre travail.

Ensuite nous avons décrit et détaillé les deux approches dans le troisième chapitre, pour arriver par la suite à la méthode hybride qui combine le seuillage itératif (ISODATA) proposée par Velasco en 1980 avec la théorie de graphes (Graph cuts), qui est une méthode de

segmentation interactive basée sur les travaux de Boykov et Jolly (2001) dans le quatrième chapitre, où nous avons amélioré le standard algorithme de Graph cuts en segmentant l'image indépendamment du paramètre  $\lambda$  pour donner des résultats nettement meilleurs et très prometteurs par rapport l'algorithme standard des Graph cuts.

Le dernier chapitre est consacré à la classification des images cérébrales, nous avons construit un classifieur basé sur les réseaux de neurones à partir des attributs et caractéristiques des images calculés, dans le but de valider et évaluer notre algorithme. Les résultats obtenus sont présentés et discutés.

Nous avons aussi détaillé la base de données dans ce dernier chapitre, elle présente une référence très utile pour la comparaison et l'évaluation de notre algorithme.

Cette thèse s'achève par une conclusion générale qui résume et met en valeur le travail que nous avons réalisé.

# 1

## LES TUMEURS CEREBRALES

### 1. INTRODUCTION

Au cours de ces dernières décennies, les chercheurs se sont intéressés de plus en plus par les tumeurs cérébrales. Cet intérêt s'explique par l'impact qu'elles possèdent sur la vie des êtres humains.

Les tumeurs cérébrales, sont des masses qui proviennent de la division ou de la multiplication de cellules normales ou néoplasme. Les excroissances du néoplasme sont divisées en deux catégories bien différentes : Les tumeurs malignes et les tumeurs bénignes.

Ce premier groupe, définit la rubrique parmi lesquelles les tumeurs les plus dangereuses, et pouvant être mortelles. Celles-ci, sont capables d'envahir, de détruire et peuvent s'étendre à distance (elles se détachent de la tumeur primitive et migrent pour aller se développer dans une autre partie du corps humain : métastase).

Les tumeurs dites bénignes sont décrites comme inoffensives tout pendant qu'elles ne deviennent pas des métastatiques. Les tumeurs n'étant pas métastatique sont dites primaires alors que les métastatiques ayant migré sont dites secondaires [1], [3].

Chaque type de tumeur a ses particularités en termes de topographie préférentielle, d'histologie et de pronostic. Chacun de ces termes a sa signification propre, mais en fait ils sont étroitement reliés entre eux. A telle topographie est associée l'agressivité de la tumeur en terme de développement, de conséquence neurologique, d'accessibilité au traitement chirurgical. A telle histologie est associé l'origine tissulaire de la tumeur et son degré de malignité. A tel pronostic est lié le degré d'extension de la tumeur au moment du diagnostic autant que son

## 1. Les tumeurs cérébrales

grade histologique. A ce jour, la classification histologique de la tumeur sert toujours d'outil de base pour l'estimation d'un pronostic global d'un terme de survie.

## 2. ANATOMIE DU CERVEAU




Figure 1.1 : Anatomie du cerveau.

Le système nerveux est formé de deux parties :

*Le système nerveux central*, constitué par l'encéphale comprenant le cerveau, le tronc cérébral, et le cervelet situés dans la boîte crânienne, et la moelle épinière située dans le canal rachidien. Son rôle est de recevoir, enregistrer, interpréter les signaux qui parviennent de la périphérie, et l'organiser la réponse à envoyer (Fig1.1).

*Le système nerveux périphérique*, constitué par les nerfs crâniens et les nerfs spinaux qui sont rattachés au système nerveux central. Son rôle est de conduire jusqu'au système nerveux central les informations issues des récepteurs périphériques de la sensibilité ou de la douleur, et de transmettre les ordres moteurs émis par les centres nerveux [2].

## 1. Les tumeurs cérébrales

### 2.1. L'ENCEPHALE

Est en entier situé dans la boîte crânienne (Fig.1.2). Il est constitué par :  
Le cerveau, le tronc cérébral, et le cervelet.




Figure 1.2 : L'encéphale

### 2.2. SUBSTANCE GRISE ET BLANCHE

Le système nerveux central est formé de deux parties différentes caractérisées par leur teinte : la substance grise et la substance blanche (Fig.1.3).




Figure 1.3 : Substance blanche et grise

## 1. Les tumeurs cérébrales

### 2.3. ELEMENTS CELLULAIRES DU SYSTEME NERVEUX

La substance grise est formée de cellules ; la substance blanche est formée de fibres. La cellule et la fibre ne sont que les deux parties d'un même élément essentiel du système nerveux : le neurone.

#### 2.3.1. LE NEURONE

Le neurone est une cellule anatomiquement et physiologiquement spécialisée dans la réception, l'intégration et la transmission d'informations. En effet, le neurone isolé n'existe pas. Chacun d'entre eux est intégré dans des réseaux multiples, ordonnés et hiérarchisés chargés de recevoir ou transmettre un signal, ou de coordonner une fonction complexe (Fig.1.4).




Figure 1.4 : Neurone

La transmission nerveuse se fait par l'intermédiaire de plusieurs neurones qui sont en rapport les uns avec les autres par leurs dendrites ou par l'articulation d'un axone avec les dendrites d'une ou de plusieurs cellules voisines. La jonction entre les éléments de deux cellules constitue une synapse.

#### 2.3.2. LES CELLULES GLIALES

Les cellules gliales constituent le tissu de soutien du système nerveux. Elles assurent le lien avec les vaisseaux sanguins et apportent les nutriments essentiels au fonctionnement métabolique du système nerveux. Contrairement aux cellules neuronales, les cellules gliales peuvent se multiplier, voire proliférer et devenir cancéreuses. On distingue plusieurs types de cellules gliales : les astrocytes, les oligodendrocytes, la microglie et les cellules épendymaires.

## 1. Les tumeurs cérébrales

### a. LES ASTROCYTES

Ce sont les cellules les plus nombreuses de l'encéphale. Véritable tissu de soutien, elles assurent le support métabolique et la synthèse des principaux constituants du système nerveux.

### b. LES OLIGODENDROCYTES

Ce sont des cellules plus petites et moins nombreuses que les astrocytes. Dans les nerfs périphériques, les cellules de la gaine de Schwann sont analogues aux oligodendrocytes.

### 2.3.3. LES CELLULES EPENDYMAIRES

Ce sont des cellules cylindriques ou cubiques à noyau volumineux qui recouvrent et tapissent les cavités ventriculaires de l'encéphale et le canal central de la moelle épinière.

## 2.4. LES LOBES CEREBRAUX

Les scissures délimitent 4 grands lobes : le lobe frontal en avant, le lobe pariétal et le lobe temporal au milieu, le lobe occipital en arrière (Fig.1.5).




Figure 1.5 : Les lobes externes du cerveau humain

## 3. CLASSIFICATION DES TUMEURS CÉRÉBRALES

Il est nécessaire de trouver une classification simple, utile et mémorisable de l'ensemble des tumeurs cérébrales. La topographie est un critère utile, mais l'histologie de la tumeur est le critère majeur de classement puisqu'il va aussi nous indiquer le pronostic global.



## 1. Les tumeurs cérébrales

### 3.1. CLASSIFICATION SUIVANT L'HISTOLOGIE

L'examen histologique permet de confirmer la nature de la lésion et, surtout, son degré de malignité. La classification utilisée ce jour est celle de l'OMS (Organisation Mondiale de la Santé); elle attribue à chaque variété de tumeur son grade de malignité, ce qui est une information d'ordre pronostique.

Grade I : Astrocytomepilocytaire curable par chirurgie

Grade II : Tumeurs oligodendrogiales

- Oligoastrocytome deux types de cellules : astrocytes et oligodendrogiales
- Oligodendrogliome, infiltrant bien différenciés.
- Astrocytome diffus, tumeur de l'adulte jeune, évolution lente vers astrocytome anaplasique puis glioblastome multiforme.

Grade III : Gliome malins

- Oligodendrogliome anaplasique
- Oligoastrocytome anaplasique
- Astrocytome anaplasique, anaplasie focale ou diffus

Grade IV

- Glioblastome multiforme (néovascularisation, nécrose, évolution rapidement péjorative).

Les tumeurs primitives de l'encéphale, c'est-à-dire d'origine gliale, sont les plus fréquentes des tumeurs intracrâniennes.

Nous les désignons sous le nom générique de gliomes. Nous distinguons les astrocytomes, les épendynomes et les oligodendrocytomes qui sont des tumeurs dérivées du tissu glial composé d'astrocyte, d'oligodendrocytes, et de cellule épendymaires.

Le tableau 1.1 présente les principales catégories de tumeurs primitives intracrâniennes dont les plus fréquentes.

## 1. Les tumeurs cérébrales

<b>Tumeurs primitives du cerveau</b>		
<i>Tumeurs gliales</i>	Astrocytome	Astrocytomepilocytaire Astrocytome fibrillaire Astrocytome anaplasique
	Glioblastome Oligodendrocytome Ependynome Lymphomemalin	
Tumeurs mésoenchymateuse		
<b>Tumeurs primitives du cervelet</b>		
Tumeurs gliales	Astrocytomepilocytaire Ependynome	
Tumeurs vasculaires	Hémangioblastome Cavernomes	
<b>Tumeurs primitives des méninges</b>		
	Méningiome Sarcome méningé Hémangiosarcome	
<b>Tumeurs d'origine embryonnaire</b>		
	Kyste dermoïde Kyste épidermoïde Médulloblastome du IV <sup>e</sup> ventricule	
<b>Tumeurs dites de la ligne médiane</b>		
	Adénomes hypophysaires Craniopharyngiome	

Tableau .1.1 : principales classes de tumeurs cérébrales primitives.

## 4. PRINCIPALES TUMEURS CEREBRALES PRIMITIVES

La numérisation des acquisitions issues des différentes techniques comme l'IRM ou le Scanner offre la matière au développement de systèmes automatiques d'aide au diagnostic.

Dans le cas particulier du diagnostic des tumeurs cérébrales, cette aide consiste à détecter et à localiser précisément les tumeurs sur les clichés radiologiques.

## 1. Les tumeurs cérébrales

Les tumeurs du cerveau sont soit bénignes soit malignes. Il est nécessaire de distinguer les tumeurs primitives, se développant à partir de cellules du cerveau et les tumeurs secondaires qui correspondent à des tumeurs cancéreuses de nature métastatique (provenant d'un autre cancer) (Fig.1.6) [4].




Figure 1.6 : Siège des néoplasies les plus courantes

### 4.1. ASTROCYTOMES

Les astrocytomes sont des tumeurs de la lignée astrocytaire, c'est-à-dire développées à partir des astrocytes composant la glie, tissu de soutien cérébral.

C'est une tumeur cérébrale infiltrante, qui ne présente généralement pas de limite nette avec le cerveau avoisinant, et qui est maligne dans 50% des cas.

La croissance tumorale est plus ou moins rapide suivant le degré de malignité. L'augmentation du volume tumoral déforme les structures cérébrales adjacentes et les envahit.

Le grade de la tumeur est fait d'une addition de 4 critères histologiques caractéristiques retrouvés à l'examen au microscope. Ces critères sont : Atypies nucléaires (anomalies des noyaux des cellules épithéliales),

## 1. Les tumeurs cérébrales

mitoses (étape de la division cellulaire correspondant à la division des noyaux), prolifération vasculaire endothéliale (néovaisseaux), nécrose cellulaire. Lorsque ces quatre anomalies sont présentes, on parlera d'astrocytome grade 4 ou de glioblastome, car la différence entre ces deux types de tumeurs est faible.




Figure 1.7 : Astrocytome kystique du cervelet

[1] (pilocytaire)

(Le siège hémisphérique cérébelleux est privilégié.

L'aspect kystique avec un nodule mural est fréquemment rencontré).

## 4.2. GLIOBLASTOME

Ce sont les tumeurs astrocytaires les plus malignes (figure.1.8.). Ils sont primitifs, ou proviennent de la transformation maligne d'un astrocytome préexistant. Ils surviennent à tous les âges mais avec un pic de fréquence entre 50 et 60 ans. Ce sont des tumeurs en général volumineuses, développées dans le cortex (Fig1.1) et la substance blanche (Fig.1.3). Le faible volume de la lésion ne signifie pas que leur malignité est moindre[1].

## 1. Les tumeurs cérébrales




Figure 1.8 : Glioblastome multiforme

Cet examen montre la présence d'une récurrence du glioblastome multiforme pariétal droit, 3 mois après son excision [5].

### 4.3. OLIGODENDROGLIOME

Les oligodendrogliomes représentent 5% des tumeurs cérébrales primitives [1]. La localisation au cervelet est exceptionnelle. C'est une tumeur infiltrante développée à partir des oligodendrocytes. Elle est bien circonscrite dans le cerveau, souvent calcifiée, assez peu vascularisée, et d'évolution lente.

Le premier symptôme révélateur est l'épilepsie, puis tardivement se développent une hypertension intracrânienne et les autres signes habituels des tumeurs évolutives.

Le diagnostic neuroradiologique de la nature de la tumeur est souvent possible en raison de la présence de micro calcification et d'une faible injection par le produit de contraste.

## 1. Les tumeurs cérébrales




Figure 1.9 : Oligodendrogliome IRM du cerveau

coupe coronale T2.

1, Lobe temporal droit. 2, Ventricule latéral. Flèche, Masse hétérogène infiltrant la partie antérieure des deux lobes frontaux et le corps calleux. Il existe des changements kystiques dans la tumeur et un effet de masse sur le système ventriculaire [6].

### 4.4. EPENDYMOMES

Ce sont des tumeurs malignes développées à partir des cellules épendymaires qui bordent les cavités ventriculaires cérébrales. Un épendymome peut devenir anaplasique. Il est cité l'existence fréquente d'anomalies cytogénétiques. Leur exérèse chirurgicale complète est rare. La survie à 5 ans est d'environ 20 à 30% [1].



Figure 1.10 : Ependymome

IRM coupe sagittale

Tumeur occupant tout le IV ventricule descendant sur la face postérieure de la moelle (flèches) remontant vers l'aqueduc (tête de flèche) [7].

## 1. Les tumeurs cérébrales

### 4.5. LYMPHOME PRIMITIF CEREBRAL

Tumeur maligne d'origine mésoenchymateuse, le lymphome primitif cérébral est une prolifération de cellules lymphocytaires de types B. le lymphome affecte les patients immunodéficients, et les patients âgé de plus 60ans. La prolifération tumorale se présente au scanner comme une lésion mal limitée, et le contraste est souvent situé au contact des parois ventriculaires cérébrales.

Une recherche de cellules lymphomateuses dans le LCS (liquide cérébro-spinal) est recommandée pour le diagnostic si une biopsie cérébrale ne peut être réalisée [1].




Figure 1.11: Lymphome.

Coupe IRM axiale en séquence T2 (après traitement) : la lésion a régressé de volume, elle est en hypersignal T2 avec persistance de l'œdème périlésionnel [8].

## 1. Les tumeurs cérébrales




Figure 1.12 : Lymphome.

Coupe IRM axiale en séquence T1 après contraste (après traitement) : l'injection de contraste montre le rehaussement du corps calleux [8].

### 4.6. MENINGIOMES

Les méningiomes sont considérés comme des tumeurs bénignes dont le traitement chirurgical assure le plus souvent la guérison définitive [1].

Le diagnostic neuroradiologique d'un méningiome est en règle facile. Sur un scanner cérébral effectué avec une injection de produit de contraste, nous découvrons une lésion arrondie et régulière, paraissant accolée à la voûte crânienne sur plusieurs centimètres, prenant fortement et de façon homogène le contraste iodé.

À l'IRM, le méningiome est aussi facilement visible, et prend le contraste après injection de gadolinium [1].



Figure 1.13 : Tomodensitométrie axiale du cerveau.

Coupe axiale.

1, Effet de masse calcifié. 2, Sinus frontal gauche. 3, Cavité orbitaire gauche. 4, Lobe temporal. 5, IVème ventricule. 6, Cervelet.



## 1. Les tumeurs cérébrales

Chez cette patiente, il existe donc

- Un premier effet de masse bien délimité, calcifié, de 3cm de diamètre, correspondant à un méningiome de la gouttière olfactive.
- Un deuxième effet de masse bien délimité, de 5,5cm de diamètre, se rehaussant fortement après injection de contraste et qui correspond à un méningiome para sagittal pariétal gauche (avec présence d'un œdème péri lésionnel) [9].

### 4.7. NEURINOME DE L'ACCOUSTIQUE

Le neurinome est une tumeur bénigne bien encapsulée, développée dans la gaine de Schwann (Fig.1.14) du nerf cochléo-vestibulaire, et plus précisément sur le nerf vestibulaire inférieur dans le conduit auditif interne

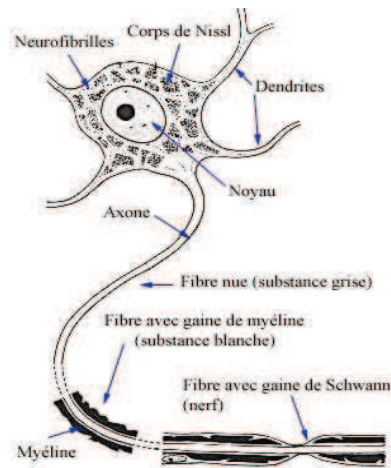


Figure 1.14 : Structure d'un neurone

C'est une tumeur avec un potentiel évolutif variable mais une croissance faible, de l'ordre de 0,2mm à 2mm par an [1].

## 1. Les tumeurs cérébrales




Figure 1.15 : Nérinome de l'accoustique.

Coupe sagittale pondération T1, après injection de chélates de gadolinium. 1, Sinus maxillaire. 2, Cavité orbitaire 3, Noyau caudé. 4, Ventricule latéral. Flèche, Schwannome vestibulaire [10].

### 4.8. KYSTES DERMOÏDES ET EPIDERMOÏDES

Les kystes dermoïdes et épidermoïdes sont des formations tumorales bénignes, de croissance lente, résultant du développement de restes embryonnaires de cellules ectodermiques.

Au scanner, la lésion apparaît hypodense en raison de son important contenu graisseux. En IRM, l'aspect hyper ou hypointense de la lésion dépend de son contenu en cholestérol et en eau. [1].




Figure 16 : Epidermoïde.

Tomodensitométrie montrent une grande masse, avec diminution de l'atténuation principalement, situé dans la fosse moyenne du crâne avec extension dans la citerne suprasellaire.

## 1. Les tumeurs cérébrales




Figure 1.17 : Kyste dermoïde cérébelleux.

IRM séquence en pondération T2. Hyposignal intense inhabituel. Opératoirement, contenu kystique verdâtre riche en hémossiderine [11].

### 4.9. HEMANGIOBLASTOMES

Les hémangioblastomes sont des tumeurs mésoenchymateuses très vascularisées, et siégeant avec prédilection dans le cervelet où la tumeur de petit volume se développe dans le parenchyme, ou dans la paroi d'un volumineux kyste tumoral hyperalbumineux.

Le scanner avec injection permet de découvrir facilement la lésion principale. L'IRM lui est supérieure pour détecter des lésions infra-centimétriques dans le cervelet et surtout dans la moelle épinière, car elles prennent fortement le contraste au gadolinium. Seule l'IRM peut assurer un suivi radiologique [1].




Figure 1.18 : Hémangioblastome cérébelleux

IRM cérébrale (Coupe axiale, pondération T2).1, Sinus maxillaire droit.  
2, Hémisphère cérébelleux droit. Flèche, Lésion kystique

## 1. Les tumeurs cérébrales




Figure 1.19: Hémangioblastome cérébelleux [12].

IRM cérébrale (Coupe sagittale, pondération T1 et après injection intraveineuse de contraste).1, Pôle frontal. 2, Ventricule latéral. 3, Moelle épinière. Flèche, Lésion kystique infra-tentorielle ayant un nodule mural (qui se rehausse fortement après injection de contraste)

### 4.10. ADENOMES HYOPHYSAIRES

La majorité des tumeurs hypophysaires sont représentées par les adénomes hypophysaires qui sont dérivés du tissu adrénohypophysaire, c'est-à-dire de l'hypophyse antérieure, portion la plus glandulaire qui sécrète les hormones trophiques, ils sont des tumeurs bénignes [1].




Figure 1.20 : IRM du cerveau Macroadénome de l'hypophyse.

## 1. Les tumeurs cérébrales

Coupe axiale. Pondération T1.1, Nerf optique (cavité orbitaire droite).  
2, Gyrus rectus (lobe frontal gauche). 3, Lobe temporal (gauche). 4,  
Vermis (cervelet). Flèche, Macro-adenome de l'hypophyse [13].

## 5. CONCLUSION

Nous avons décrit dans ce chapitre le cerveau humain et leurs principales composantes, et présenté les principales tumeurs cérébrales existantes et leur classification selon le degré de malignité.

Cette étude nous permet de mettre en évidence le sujet lié à notre problématique de segmentation des tumeurs cérébrales sur les images issues principalement de l'IRM.

La segmentation de telles images, même en l'absence de tumeur cérébrale, est une tâche non triviale. Le cerveau est en effet un organe complexe, composé de différentes structures anatomiques qui s'entremêlent. De plus, la frontière physique entre ces différentes structures est particulièrement délicate à définir, même pour un œil expert.

La segmentation et la détection des tumeurs cérébrales sont des tâches ardues du fait de la complexité de l'élément recherché ; le nombre de tumeurs est variable, leurs formes et caractéristiques visuelles sont diverses et variées.

# 2

## APPROCHES DE SEGMENTATION D'IMAGES (ÉTAT DE L'ART)

### 1. INTRODUCTION

La segmentation d'images concerne aujourd'hui de nombreux travaux en imagerie médicale, elle représente une partie de grande importance dans la chaîne de traitement d'images.

Nous présentons dans ce chapitre l'état de l'art de deux approches distinctes très connues dans la littérature : le seuillage (*threslhoding*), et la coupe des graphes (*graph cut*). La combinaison et l'hybridation de ces deux approches, qui sera présenté dans la suite, nous a permet de trouver des nouveaux résultats satisfaisants dans la segmentation des images médicales et plus précisément des images cérébrales.

### 2. L'HISTOGRAMME

Pour mieux comprendre le seuillage nous commençons par l'histogramme.

L'histogramme d'une image est la fonction qui associe à chaque valeur d'intensité le nombre de pixels dans l'image ayant cette valeur.

Il indique pour chaque valeur entre le noir (0) et le blanc (255), le nombre de pixels de cette valeur dans l'image, en abscisse le niveau de gris (de 0 à 255), et en ordonné le nombre de pixels, voir figure.2.1.

## 2. Etat de l'art




Figure 21 : Exemple d'histogramme

Dans le seuillage, l'interprétation de l'histogramme se fait par détecter ses modes (pics) pour distinguer les objets des fonds.

L'histogramme est unimodal s'il est formé d'un seul pic qui représente les pixels de l'objet ou ceux du fond, comme le montre la figure Fig.2.2.




Figure 22 : Histogramme unimodal.

Il est bimodal s'il existe deux modes séparés par une vallée, il indique l'existence d'un objet sur le fond (figure Fig.2.3).

## 2. Etat de l'art




Figure 23 : Histogramme bimodal.

Et enfin il multimodal s'il existe plus de deux modes indiquant l'existence de plusieurs classes dans l'image (figure.2.4).




Figure 24 : Histogramme multimodal.



### 3. APPROCHES DE SEUILLAGE POUR LA SEGMENTATION DE L'IMAGE

Généralement le seuillage est une technique très simple mais d'une grande efficacité dans le domaine de traitement d'images. En raison de sa simplicité le seuillage est très sollicité pour l'implémentation en temps réel. Son objectif majeur est la séparation des objets des fonds sans qu'il y ait un chevauchement. Le résultat obtenu de l'opération de seuillage est une image binaire, et dans de nombreuses applications de traitement d'images, l'utilisation de l'image binaire peut diminuer le coût de calcul des étapes successives comparées aux images en niveaux de gris. Le multi seuillage a pour objectif de segmenter l'image en deux (ou plusieurs) classes. Cette tâche consiste à effectuer une partition de l'histogramme en niveaux de gris en utilisant un (ou plusieurs) seuil, et à assigner à chaque pixel la classe la plus proche (au sens métrique) auquel il appartient et sur l'utilisation du contraste des différents contours détectés.

Différents facteurs peuvent compliquer l'opération du seuillage, comme la présence du bruit non stationnaire et corrélé, l'éclairage ambiant, l'agitation de niveaux de gris dans l'objet et le fond, le contraste insuffisant, et la taille de l'objet sans rapport avec la scène.

Les techniques de binarisation d'images en niveaux de gris peuvent être classées en deux catégories : seuillage globale, où un seul seuil est utilisé dans toute l'image pour la diviser en deux classes (objet et fond), et seuillage local où les valeurs des seuils sont déterminées, pixel par pixel ou bien région par région. D'autres contributions dans la littérature ont aussi proposé des méthodes hybrides qui combinent à la fois les techniques locales et globales.

#### 3.1. LES METHODES GLOBALES

Ces méthodes reposent sur l'exploitation de l'histogramme qui caractérise la distribution des niveaux de gris :

$$p(i) = \frac{h(i)}{N} \quad (2.1)$$

## 2. Etat de l'art

Avec

$h(i)$  : Le nombre de pixels ayant le niveau de gris  $i$ .

$p(i)$ : Est la probabilité ou la fréquence d'apparition du niveau de gris  $i$ .

$N$  : Le nombre total de pixels dans l'image.

### 3.1.1 METHODE D'OTSU ET SES DERIVES

La méthode d'OTSU [15] est considérée comme la méthode de référence. Elle est l'une des méthodes de seuillage les plus citées et référencées dans l'état de l'art.

OTSU a décrit 3 critères discriminants :

- L'interclasse.
- L'intra classe.
- La variance totale.

Il a proposé de réaliser une maximisation de ces critères. Le but majeur de cet algorithme est la binarisation d'images à niveaux de gris. Il consiste à séparer les pixels de l'image en deux classes, la première ayant un niveau maximal (255) et la seconde un niveau minimal (0), la classe « fond » regroupe tous les pixels ayant un niveau de gris inférieur au seuil  $t$ , et la classe « objet » contient tous les pixels de niveaux de gris supérieur à  $t$ .

Cette méthode de binarisation nécessite le calcul a priori de l'histogramme. Ensuite, la séparation en deux classes est réalisée. Les résultats obtenus sont satisfaisants dans le cas où le nombre de pixels dans chaque catégorie sont proches les uns des autres. Elle est basée sur le calcul de la densité de probabilité des différents pixels de l'image obtenus après l'égalisation de l'histogramme dans le but de calculer les différents critères.

## 2. Etat de l'art

$$p_i = \frac{h(i)}{\sum_{j=0}^{L-1} h(j)} \quad (2.2)$$

Avec

$$p_i \geq 0 \quad \text{et} \quad \sum_{i=0}^{L-1} p_i = 1$$

$h(i)$  : Le nombre d'occurrences du pixel de niveau de gris  $i \in [0 \ L - 1]$  où  $L$  : le nombre total des niveaux de gris.

Dans le cas de deux classes (binarisation), le seuil optimal est celui qui maximise le ratio interclasse de la variance totale.

$$t^* = \text{Arg}_{0 \leq t \leq L-1} \max \frac{\sigma_B^{2(t)}}{\sigma_T^2} \quad (2.3)$$

Avec

$$\sigma_T^2 = \sigma_B^2 + \sigma_w^2 \quad (2.4)$$

$$\sigma_B^2 = p_1 p_2 (\mu_1 - \mu_2)^2 \quad (2.5)$$

$$\sigma_T^2 = \sum_{i=1}^{L-1} p_i (i - \mu)^2 \quad (2.6)$$

$$\sigma_w^2 = \sum_{i=0}^t p_1 (i - \mu_1)^2 + \sum_{i=t+1}^{L-1} p_2 (i - \mu_2)^2 \quad (2.7)$$

$\mu_1, \mu_2$  et  $\mu$  représentent respectivement les niveaux de gris des classes  $c_1, c_2$  et de l'image.

$$\mu_1 = \sum_{i=1}^t i \frac{p_i}{p_1} \quad (2.8)$$

$$\mu_2 = \sum_{i=i+1}^{L-1} i \frac{p_i}{p_2} \quad (2.9)$$

$$\mu = \sum_{i=1}^{L-1} ip_i \quad (2.10)$$

L'existence d'un seul seuil pour maximiser le critère constitue un handicap majeur de cette méthode. Reddi et al [16], ont proposé une généralisation de cette méthode pour la détection de plusieurs seuils. Il existe une deuxième limite de la méthode d'OTSU concerne le regroupement des pixels en 2 classes, où l'efficacité n'existe que lorsqu'il y a un seul objet à segmenter dans l'image. Cheriet et al [17] ont proposé d'appliquer la méthode d'OTSU de façon récursive pour segmenter un seul objet à la fois dans l'image, puis regrouper tous les objets dans la segmentation finale.

En 1986 Kittler et Illingworth [22] ont proposé une méthode plus robuste afin de calculer la valeur du seuil  $t$  qui sépare les modes significatifs de l'histogramme. Les auteurs ont supposé que l'histogramme des niveaux des gris est une estimation de la fonction de densité de la probabilité d'un mélange de population formés des niveaux de gris des objets et du fond. Cette méthode repose sur l'erreur minimale de seuillage, le seuil optimal est obtenu en optimisant le taux d'erreur de classification des pixels.

Le seuil optimal est obtenu en minimisant la formule suivante :

$$J_1(t) = 1 + 2[p_0(t)\log\sigma_0(t) + p_1\log\sigma_1(t)] - 2[p_0(t)\log p_0(t) + p_1(t)\log p_1(t)] \quad (2.11)$$

## 2. Etat de l'art

Avec

$$p_0(t) = \sum_{i=0}^t h(i) \quad (2.12)$$

$$p_1(t) = \sum_{i=t+1}^{L-1} h(i) \quad (2.13)$$

$$\mu_0(t) = \frac{\sum_{i=0}^t ih(i)}{p_0(t)} \quad (2.14)$$

$$\mu_1(t) = \frac{\sum_{i=t+1}^{L-1} ih(i)}{p_0(t)} \quad (2.15)$$

### 3.1.2. METHODES BASEES SUR LE PRINCIPE DE L'ENTROPIE

La méthode de seuillage par maximisation de l'entropie fait appelle à la théorie de l'information. L'entropie mesure l'information moyenne donnée par la segmentation. C'est une mesure de la dispersion ou du désordre associé à un ensemble fini de données probabilistes. L'entropie est maximale pour un ensemble de  $D$  probabilités  $p_i$  équiprobables de valeur  $p_i = 1/D$ . L'entropie est minimale pour une probabilité certaine de valeur maximale  $p_i = 1$ .

$$E = - \sum_{i=1}^L \log(p_i) \quad (2.16)$$

Avec  $E$  est l'entropie de l'histogramme et  $L$  est le nombre total des niveaux de gris dans l'image.

La probabilité d'apparition du niveau de gris :

$$p_i = N_i/N \quad (2.17)$$

## 2. Etat de l'art

Avec  $N$  est le nombre total des pixels dans l'image.

Pun [28] a introduit le principe de l'entropie dans les algorithmes de seuillage. L'auteur a proposé d'utiliser une mesure de l'entropie pour fixer une valeur du seuil  $T$  dans l'histogramme des niveaux de gris. Il a introduit les deux fonctions d'entropies suivantes :

$$E'_N(T) = - \sum_{i=1}^s p_i \log p_i \quad (2.18)$$

$$E'_B(T) = - \sum_{i=s+1}^N p_i \log p_i \quad (2.19)$$

Avec  $s$  est la valeur du seuil supposé.

Où  $E'_N(T)$  et  $E'_B(T)$  sont considérées en général comme des mesures a postériori de l'information associée à chacune des régions "claire" et "sombre" de l'image.

La valeur de seuil recherchée est obtenue lorsque le maximum de la fonction  $E'(T)$  est atteint.

Avec

$$E'(T) = E'_N(T) + E'_B(T) \quad (2.20)$$

Dans ses travaux, Pun [28] a démontré que la recherche du maximum de la fonction  $E'(T)$  revient tout équivalent à rechercher le maximum de la fonction d'évaluation  $E(T)$  suivante :

$$E = \left( \frac{E'_N(T)}{E'(T)} \right) * \frac{\log P_T}{\log \max[P_1, \dots, P_T]} + \left[ 1 - \frac{E'_N(T)}{E'(T)} \right] * \frac{\log(1 - P_T)}{\log \max[P_{T+1}, \dots, P_N]} \quad (2.21)$$

## 2. Etat de l'art

Avec

$$P_T = - \sum_{i=1}^s p_i \quad (2.22)$$

Deux années après les résultats trouvés par Pun, Johanson et Bille [30]. Ont proposé une méthode qui utilise l'entropie de l'histogramme des niveaux de gris d'une image numérique. Ils séparent l'ensemble des niveaux de gris en deux parties de manière à minimiser l'interdépendance entre elles.

Kapur et al [33] apporte d'autres modifications aux travaux de Johanson et Bille par la maximisation de l'entropie totale de Shanon, sa contribution suppose que la classe  $c_1$ , appartient « objet » et la classe  $c_2$  appartient au « fond », possèdent deux densités de probabilité indépendantes :

$$c_1 = \frac{p_1}{p_1}, \frac{p_2}{p_1}, \dots, \frac{p_t}{p_1} \quad (2.23)$$

$$c_2 = \frac{p_{t+1}}{p_2}, \frac{p_{t+2}}{p_2}, \dots, \frac{p_{L-1}}{p_2} \quad (2.24)$$

Les entropies des deux classes  $c_1$  et  $c_2$  sont définies comme suit :

$$H_1 = - \sum_{i=0}^t \frac{p_i}{p_1} \log \left( \frac{p_i}{p_1} \right) \quad (2.25)$$

$$H_2 = - \sum_{i=t+1}^{L-1} \frac{p_i}{p_2} \log \left( \frac{p_i}{p_2} \right) \quad (2.26)$$

Le seuil optimal  $t^*$  est défini comme étant le niveau de gris qui maximise les deux entropies  $H_1$  et  $H_2$ :

## 2. Etat de l'art

$$t^* = \arg \max_{0 \leq t \leq L-1} \{H_1(t) + H_2(t)\} \quad (2.27)$$

Cette méthode permet aussi de calculer plusieurs seuils  $T = \{t_1, t_2, \dots, t_{k-1}\}$ , en maximisant la fonction suivante :

$$J(T) = \sum_{k=1}^k H_k \quad (2.28)$$

Avec :

$$H_k = \sum_{i=t_{k-1}}^{t_k-1} \frac{p_i}{p_k} \log\left(\frac{p_i}{p_k}\right) \quad (2.29)$$

Et

$$p_k = \frac{1}{N} \sum_{i=t_{k-1}}^{t_k-1} h(i) \quad (2.30)$$

La méthode d'entropie de Renyi proposée par Sahoo [35], est une extension de la méthode de Kapur, elle utilise deux distributions de probabilité (objet et fond) tirées de la distribution l'entropie d'originale.

L'entropie d'ordre de Renyi est définie par l'équation suivante :

$$H_T^\alpha = \frac{1}{1-\alpha} \ln \sum_{i=0}^N (p_i)^\alpha \quad (2.31)$$

Avec le paramètre réel  $\alpha \neq 1$ .

Sahoo [36] a fait appel à l'entropie de Tsallis-Havrda-Charvat. Elle est basée sur le seuillage de l'histogramme. Le calcul du seuil optimal est



## 2. Etat de l'art

obtenu via une maximisation de l'énergie de l'entropie Tsallis des classes fond et objet.

L'entropie de Tsallis de la classe « objet : O »

$$S_O^q(t) = \frac{1 - \sum_{i=1}^t \left(\frac{p_i}{p_t}\right)^q}{q - 1} \quad (2.32)$$

L'entropie de Tsallis de la classe « objet : B »

$$S_B^q = \frac{1 - \sum_{i=t+1}^N \left(\frac{p_i}{1-p_t}\right)^q}{q - 1} \quad (2.33)$$

L'entropie totale de Tsallis :

$$S_T^q = [S_O^q(t) + S_B^q(t) + (1 - q)S_O^q(t)S_B^q(t)] \quad (2.34)$$

Avec le paramètre réel  $q$  appelé indice entropique.

Les méthodes de seuillage d'entropie exponentielle ont été défini par Nakib et al [37], le seuil optimal peut être déterminé en maximisant l'entropie exponentielle relative à la classe fond et à la classe objet.

$$H^\alpha = \left( \sum_i (p_i)^\alpha \right)^{\frac{1}{1-\alpha}} \quad (2.35)$$

### 3.1.3. METHODES BASEES SUR L'HISTOGRAMME CONVEXE

Nous citons Parmi les méthodes globales, les méthodes basées sur l'analyse des concavités de l'histogramme des niveaux de gris. En réalité il n'est pas aussi aisé de trouver la vallée de l'histogramme lorsque les distributions des niveaux de gris des points images du fond et des objets présentent un fort degré de chevauchement, dans ce cas il est préférable de choisir le seuil en analysant les concavités de l'histogramme. Rosenfel et al [26], ont proposé une méthode de seuillage par enveloppe convexe de l'histogramme des niveaux de gris, ils ont construit l'enveloppe de convexe de l'histogramme des niveaux de gris. Le seuil choisit sera parmi ceux qui correspondent à des maxima relatifs de la différence entre l'histogramme et son enveloppe convexe.

Soit  $h$  est l'histogramme des niveaux de gris de l'image et  $\bar{h}$  son enveloppe polygonale convexe, les concavités de  $h$  sont déterminées à partir de la différence  $h - \bar{h}$ .

$h(g_i)$  et  $\bar{h}(g_i)$  sont les valeurs respectives des niveaux de gris  $g_i$  de  $h$  et  $\bar{h}$  respectivement. Les choix de seuils possibles correspondent à des niveaux de gris pour lesquels  $\bar{h}(g_i) - h(g_i)$  possède un maximum local. Les valeurs maximales de  $h(g_i) - \bar{h}(g_i)$  correspondent approximativement aux différentes vallées de l'histogramme, les vallées étant décalées vers les pics d'amplitude la plus élevée. Cependant ces maxima ne correspondent pas tous à de bonnes valeurs pour le seuillage, car de grandes concavités peuvent être introduites par du bruit. Afin de supprimer totalement les concavités parasites, nous calculons un facteur de mérite (ou d'équilibre) :

$$E_i = \sum_{j=g_0}^{g_i-1} h(j) \cdot \sum_{j=g_i}^{g_N-1} h(j) \quad (2.36)$$

Le maximum local significatif présente en général le facteur d'équilibre le plus important, ce qui permet de le sélectionner sans difficulté et

sans ambiguïté. Notons que les concavités parasites possèdent un faible facteur de mérite  $E_i$ .

Kaabi et al [27] ont proposé une méthode rapide de calcul de l'enveloppe convexe en utilisant la variance interclasse comme critère de sélection d'un seuil. Cette méthode permet de seuiller l'image et de déterminer le nombre de classes désirées.

### 3.1.4. LE SEUILLAGE PAR L'APPROCHE DE CLASSIFICATION

L'approche de K-means est souvent utilisé dans les méthodes de seuillage par classification, c'est la technique de classification la plus simple, mais néanmoins sa limite concerne le choix de la partition initiale pour finaliser la segmentation représente un inconvénient majeur.

Nous trouvons aussi la méthode ISODATA [18] qui permet de choisir le nombre de classe d'une façon automatique et qui sera détaillé dans le chapitre 4.

### 3.2. LES METHODES LOCALES

Il est difficile de réaliser un bon seuillage au moyen d'un seul seuil pour certaines images à cause de certains paramètres, comme par exemple le problème de l'éclairage. En effet un éclairage homogène et uniforme d'une scène est très difficile à réaliser. Le niveau de gris moyen peut varier sensiblement selon leur orientation par rapport à la source d'éclairage. Dans une image les différents objets qui la compose peuvent avoir des dynamiques de luminances différentes, c'est pour ça que les méthodes locales sont les mieux adaptées.

Elles sont des approches différentes au même problème du seuillage. Pour la binarisation locale, la classification d'un pixel dépend non seulement du pixel lui-même mais aussi de ses informations locales. Ils cherchent à déterminer en chaque point un seuil dépendant de l'histogramme de répartition des luminances de son voisinage.

L'idée principale de ces techniques est de diviser l'image globale en sous-images (en blocs de tailles égales) puis un seuil optimal est calculé

## 2. Etat de l'art

pour chaque sous-image en utilisant les techniques classiques de seuillage global.

Chow et al [24] ont utilisé des fenêtres de 7 pixels sur 7 pixels pour une application du seuillage local d'images en radiographie médicale. Pour les fenêtres des images qui présentent un histogramme bimodal, un seuil est calculé pour chaque fenêtre, et pour les histogrammes unis ou multi modal le seuil est calculé par interpolation bilinéaire avec les seuils définis dans les fenêtres adjacentes.

Fernando et al [25] ont proposé une technique de seuillage local appliquée à l'analyse de l'angiogramme. Ils ont réalisé un partitionnement de l'image d'origine en 16 sous-images distinctes, ils ont ensuite appliqué l'algorithme de Pun [28] basé sur le calcul de l'entropie pour calculer les seuils pour chaque bloc de l'image. La convolution de l'image par un filtre passe bas permet d'éliminer les discontinuités aux frontières de chaque sous-image.

Nous trouvons aussi d'autres méthodes de seuillage local basées sur le même principe comme par exemple Chehdi et al [19], Nakib et al [20].

Les méthodes de binarisation globales ont l'avantage d'être très rapides mais le changement d'éclairage et la présence de bruit peuvent réduire la qualité de la binarisation. Cependant les méthodes de binarisation locales dépassent ces limites et sont mieux adaptées aux changements de contraste local. En revanche, elles demandent plus de calcul, ce qui les rend plus lentes que les méthodes de seuillage global.

Par ailleurs, elles peuvent conduire à des résultats de sur-segmentation des défauts et des textures du fond de l'image, et sur les images de documents textuels cela peut provoquer des difficultés à traiter les caractères dont les tailles peuvent varier puisque la taille de la fenêtre d'analyse est fixée dès le départ.

#### 4. APPROCHES DE SEGMENTATION BASEES SUR LE GRAPH CUT

La deuxième approche de segmentation est la coupe de graphe « *graph cuts* », nous donnons en premier une définition et des notions de base sur la théorie des graphes. L'idée directrice est de créer un graphe à partir de l'image.

Un graphe  $G = (V, E)$  est défini par l'ensemble  $V = \{v_1, v_2, \dots, v_n\}$  dont les éléments sont appelés sommets, ou bien nœuds (*Vertices* en anglais), et par l'ensemble  $E = \{e_1, e_2, \dots, e_m\}$  dont les éléments sont appelés arêtes, ou bien arcs (*Edges* en anglais).

Une arête  $e$  de l'ensemble  $E$  est définie par une paire non ordonnée de sommets, appelés les extrémités de  $e$ . Si  $V$  et  $E$  ont finis nous parlons alors de graphe fini.

Cette méthode repose sur les graphes de voisinage, où chaque pixel de l'image (cet ensemble noté  $P$ ) devient un nœud du graphe et les arêtes issues de ce nœud rejoignent les nœuds représentant les pixels voisins.

Nous distinguerons, en outre, deux nœuds particuliers ou terminaux liés respectivement à l'objet, ce terminal est appelé source, noté  $S$ , et au fond c'est le puits, noté  $T$ . Ces deux nœuds sont appelés nœuds terminaux. Il n'existe pas d'arête entrante dans  $S$  ni d'arête sortante de  $T$ . Le choix du système de voisinage  $N$  influe grandement sur la complexité du graphe.

Le terme de régularisation est représenté par les arêtes entre nœuds appelé *n-liens*, il traduit la notion de régionalité, et le terme d'attache aux données est codé par les arêtes entre les terminaux et les nœuds appelés *t-liens*, il traduit les propriétés de contour. Chaque arête  $(v_i, v_j) \in E$  correspond à un poids non négatif noté :  $w(v_i, v_j)$ .

La segmentation d'image par la théorie des graphes est une méthode basée sur l'énergie. *Graph cuts* elle se traduit par :

$$|C| = \sum_{e \in C} w_e \quad (2.37)$$

## 2. Etat de l'art

La coupe minimale appelée aussi *min-cut* peut être atteinte en obtenant le flot maximal (*max-flow*). Le problème de *max flow* consiste à transporter la quantité maximale possible d'une origine (*source*) à une destination (*puits*) donnée sans dépasser la capacité des arcs. Les problèmes de calcul de *max flow* ont été bien résolus par Ford-Fulkerson [38], et Dinic [39] qui seront détaillé dans le chapitre suivant.

Nous notons dans la littérature plusieurs approches de segmentation d'image basées sur la théorie des graphes, nous nous sommes intéressés par la segmentation d'image qui fait appel à la théorie de *graph cuts* y compris la segmentation interactive basée aussi sur le *graph cuts*.

La théorie de *Graph cuts* a été introduit par Greig et al [40] pour la restauration d'images binaires et ont connu un nouvel essor avec l'arrivé de l'algorithme de max flow rapide. L'extraction d'objet d'intérêt dans une image a un grand intérêt surtout lors de l'analyse des images médicales.

L'idée de base des *Graph Cuts* concerne le problème de minimisation de l'énergie à un problème de coupe minimale dans un graphe. Greig et al ont montré que cette minimisation (de type estimation du maximum à posteriori d'un champ aléatoire de Markov) peut être réalisée par la coupe minimale d'un graphe avec deux nœuds spécifiques "*source*" et "*puits*" pour la restauration d'images binaires.

Des travaux basés sur cette méthode pour traiter des problèmes non binaire ont été réalisés à la fin des années 90 comme « *S-T Graph cut* » pour les problèmes non binaire, notamment en stéréovision proposé par Roy et Cox [41] ils ont proposé de construire le graphe de manière classique pour un problème de flot maximal en image. Ils ont donné une formulation de la stéréoscopie dans laquelle les cartes de disparité sont interprétées comme des hyper surfaces séparatrices dans des variétés 3D, et ainsi calculées d'une manière renforcée avec le *graph cut*. Les cartes de disparité sont des hyper surfaces séparatrices dans une

grille 3D appartenant à un espace de disparité 3D, correspondant à une paire d'images rectifiées. Les points  $(x, y, d)$  de cet espace correspondent à un point  $(x, y)$  d'une des images de la paire, choisie comme référence, et au point  $(x + d, y)$  de la seconde image.

La plupart des travaux dans cette catégorie sont les algorithmes de coupe minimale introduit par Wu et Leahy [44] ils ont proposé une solution par un algorithme de flot maximal (Théorème de Ford-Fukderson). Cependant Shi et Malik [45], [46] ont montré que ce critère de coupe comporte plusieurs limites, en particulier il favorise notamment les petits regroupements de pixels isolés, alors ils ont proposé un nouveau critère de minimisation appelé coupes normalisées (N cut) permettant d'affranchir partiellement des biais de l'algorithme des coupes minimales.

Le "NormalizedCuts" est une méthode basée sur la théorie des graphes permettant de faire du clustering et de la segmentation. Le graphe est construit de la façon suivante : un nœud est associé à chaque pixel et des arêtes relient les pixels, leurs poids étant d'autant plus grands que les pixels sont semblables. Il s'agit alors de trouver la coupe minimale dans ce graphe n'ayant pas de terminaux (pas de source ni de puits). La recherche de la solution optimale se reformule comme la recherche de vecteurs propres d'une matrice associée au graphe.

Boykov et Kolmogorov ont utilisé à la fois le principe des *Graph cut* et les contours actifs géodésiques [52] où un voisinage étendu permet à la valeur de la coupe de s'approcher de la longueur du contour correspondant.

Zabih et Kolmogorov [23] ont proposé un algorithme de type EM (Expectation-Maximization) pour segmenter un objet, ils se sont basés sur l'approche qui consiste à se placer dans un espace des caractéristiques comme par exemple les couleurs des pixels et de les classifier en les regroupant en un certain nombre nommé paquets et d'attribuer à chaque pixel de l'image d'origine une étiquette correspondant au paquet dans lequel coïncide son point associé dans un espace des caractéristiques. Ils ont proposé un algorithme itératif avec 2 points :

## 2. Etat de l'art

E : les paquets étant fixés, nous appliquons un algorithme de *Graph Cuts* pour classer correctement les pixels en fonction de l'étiquette de leur image et des étiquettes des voisins.

M : nous fixons l'étiquetage, et nous optimisons les paramètres de description des paquets.

Rother et al [47] ont proposé de remplacer les histogrammes de luminance par deux mélanges de gaussiennes. Ce type d'algorithmes en vision est très classique.

Ils ont commencé par minimiser l'énergie par *Graph Cuts*, les paramètres étant fixés (étape M). Puis ils ont réévalué les paramètres des modèles pour la partition obtenue (étape E). Ils ont continué les itérations de ce processus.

Boykov et Jolly [48] ont proposé L'algorithme le plus connu et le plus utilisé pour minimiser des fonctions d'énergies en utilisant les Graph Cuts. Ils ont appliqué le *graph cut* interactif d'une manière itérative, permettent l'extraction facile des pixels d'intérêt (objet et fond) en raison de l'implantation des germes par l'utilisateur. Cette approche interactive donne des résultats de segmentation automatique très satisfaisant.

Boykov et Funka-Lea [29] ont proposé une méthode qui résout un problème de coupe minimale (ou de flot maximal). Ils ont montré l'optimalité de la solution apportée par les coupes de graphe ainsi que l'apport des graphes orientés par rapport aux graphes non-orientés.

Xu et al [21] ont proposé une approche de contours actifs par coupes de graphe. Son côté intérieur est contraint comme source, et son côté extérieur comme puits. En appliquant itérativement jusqu'à convergence l'algorithme de calcul de coupe minimale, nous s'assurons de l'obtention d'un minimum global.

Autre type de segmentation d'image basée toujours sur le *Graph cut* est la segmentation interactive d'images est devenue un domaine important en vision par ordinateur. Nous utilisons de plus en plus ce type d'approche pour contourner le problème de segmentation



## 2. Etat de l'art

automatique qui ne donne pas toujours des résultats satisfaisants. La méthode de segmentation interactive basée sur le *Graph cuts* prend sa fiabilité sous le contrôle des utilisateurs à travers une segmentation automatique où nous pouvons facilement faire le choix de l'objet d'intérêt à segmenter. L'approche de Peng et al [34] repose sur la pré segmentation de l'image en utilisant la ligne de partage des eaux. Le même principe a été appliqué par Lempitsky et al [32] et Chang et al [31].

## 5. CONCLUSION

Nous avons présenté dans ce chapitre les travaux et les contributions les plus importantes existantes dans la littérature, ces travaux serviront de références pour nos contributions dans le cadre de cette thèse de Doctorat.

Nous avons d'abord commencé par décrire les algorithmes de seuillage, qui utilise l'histogramme de l'image, puis nous avons cité les différents algorithmes de coupe de graphe (*Graph cut*), ayant pour objet l'explication de la théorie des graphes.

# 3

## COUPE DE GRAPHE (GRAPH CUTS) ET SEUILLAGE ITÉRATIF (ISODATA) POUR LA SEGMENTATION D'IMAGE.

### 1. INTRODUCTION

Nous présentons dans ce chapitre deux techniques de segmentation : l'algorithme de Graph cuts et le seuillage itératif (ISODATA).

Nous commençons par l'algorithme standard de Graph cuts pour la segmentation d'image, en passant par l'algorithme min cut/max flow et la minimisation de l'énergie fonctionnelle, cette technique est très utile en vision par l'ordinateur.

L'histoire de la théorie des graphes débute avec les travaux d'Euler au 18<sup>ème</sup> siècle [53] en 1736, où il proposait une solution des ponts de Königsberg, (les habitants de Königsberg se demandaient s'il était possible, en partant d'un quartier quelconque de la ville, de traverser tous les ponts sans passer deux fois par le même et de revenir à leur point de départ). Depuis cette époque la théorie des graphes s'est largement développée, et les derniers travaux en théorie de graphe sont souvent effectués par des informaticiens, du fait de l'importance qu'y revêt l'aspect algorithmique.

Aujourd'hui nous trouvons la théorie des graphes développée et appliquée dans plusieurs domaines tels que la chimie, la biologie, les sciences sociales pour les réseaux routiers et de transport, informatique...etc.

## 2. L'ALGORITHME GRAPH CUT

Un graphe est un schéma qui permet de décrire un ensemble d'objets et leurs relations, c'est-à-dire le lien entre les objets.

Les objets sont appelés les nœuds ou les sommets du graphe, un lien entre deux objets est appelé une arête.

### 2.1. DEFINITION

Un graphe  $G = (V, E)$  est défini par l'ensemble  $V = \{v_1, v_2, \dots, v_n\}$  non vide dont les éléments sont appelés sommets, ou bien nœuds (*Vertices* en anglais), et par l'ensemble  $E = \{e_1, e_2, \dots, e_m\}$  dont les éléments sont appelés arêtes, ou bien arcs (*Edges* en anglais).





Figure 3.1 : Exemple d'un graphe

Si  $V$  et  $E$  sont finis nous parlerons de graphe fini.

### 2.2. GRAPHE NON ORIENTE

Nous appelons un graphe non orienté  $G = (V, E)$  ou  $V$  est l'ensemble des sommets et  $E$  est l'ensemble des arêtes tel que : une arête  $e$  est une paire de sommets  $(i, j)$ ,  $i$  et  $j$  sont incidents à  $e$ , voir figure.3.2.




$$G = (\{1,2,3,4,5\}, \{(1,2), (1,4), (1,5), (2,3), (2,4)\}).$$

Figure 3.2 : graphe non orienté

### 2.3. GRAPHE ORIENTE

Nous appelons un graphe orienté  $G = (V, E)$  ou  $V$  est l'ensemble des sommets et  $E$  est l'ensemble des arêtes tel que : une arête  $e$  est une paire ordonnée de sommets  $(i, j)$ .

$(i, j) \in E$ , n'implique pas que  $(j, i) \in E$ ,  $i$  est l'extrémité initiale et  $j$  est l'extrémité finale de  $e$ , voir figure 3.3.



$$G = (\{1,2,3,4,5\}, \{(2,1), (2,4), (1,4), (1,5), (3,2)\}).$$

Figure 3.3 : graphe orienté.

S'il existe plusieurs arcs entre deux sommets, nous parlons d'un multigraphe (arcs multiples).

### 3. Les techniques de segmentation




Figure 3.4 : multi graphe

Nous distinguerons, en outre, deux nœuds particuliers ou terminaux liés respectivement à l'objet, ce nœud terminal est appelé source, notée  $S$ , et au fond c'est le puits, noté  $\mathcal{T}$ . Ces deux nœuds sont appelés nœuds terminaux. Il n'existe pas d'arête entrante dans  $S$  ni d'arête sortante de  $\mathcal{T}$ . Voir figure 3.5.





Figure 3.5 : exemple de source  $S$  et puits  $\mathcal{T}$ .

#### 2.4. GRAPHE VALUE

Soit un graphe valué noté  $G = (V, E, c)$  où  $G = (V, E)$  est un graphe orienté et  $c$  est fonction de coût (on dit aussi une capacité, un étiquetage, un poids, une valuation des arcs) qui à tout arc  $e=(i,j)$ , associe un réel  $v : E \rightarrow \mathbb{R}$  noté  $c_{ij}$ .

### 3. Les techniques de segmentation



$$G = (\{1,2,3,5\}, \{(1,5, \pi), (2,1,2.33), (4,1,3), (2,4,-1.5), (2,3,1), (3,2,5.2)\}).$$

Figure 3.6 : Graphe valué.

La capacité  $c_{ij}$  représente par exemple le nombre maximum de voiture par unité de temps entre deux villes  $i$  et  $j$ , ou la longueur du tronçon de route  $(i, j)$ .....etc.

#### 2.5. LE VOISINAGE

Dans un graphe non orienté le voisinage d'un nœud est l'ensemble des voisins d'un nœud sachant que le voisin d'un nœud est un nœud qui est relié à un autre par le biais d'une arête. Dans un graphe orienté, on a deux types de voisinage, le voisinage interne (par les arcs qui arrivent à ce nœud) et le voisinage externe (par les arcs qui partent de ce nœud).

Soit  $G = (V, E)$  un graphe, une arête  $e$  de l'ensemble  $E$  est définie par une paire  $(i, j)$  de sommets, appelés les extrémités de  $e$ .

Si  $(i, j) \in E$ , alors  $j$  est un successeur de  $i$ .

Si  $(j, i) \in E$ , alors  $j$  est un précédeur de  $i$ .

$i$  et  $j$  sont adjacents si  $j$  est un précédeur et/ou successeur de  $i$ .

#### 2.6. FLOT MAXIMUM

Soit un graphe orienté  $G = (V, E)$ , avec deux sommets particuliers  $S$  et  $T$  dont  $S$  n'a pas un d'arc entrant et  $T$  n'a pas d'arc sortant. Pour chaque arc  $e$ , un entier  $w(e)$  appelé sa capacité

Un flot est une application  $F$  de  $E$  dans  $R^+$  telle que

- Un flot pour chaque arc  $e$  est inférieur à la capacité :  $F(e) \leq w(e)$

### 3. Les techniques de segmentation

- Pour chaque sommet autre que  $S$  et  $T$  le flot entrant est égal au flot sortant.
- La valeur du flot  $F$  est la valeur du flot sortant de  $S$  (égal au flot entrant en  $T$ ).

Données un graphe dirigé  $G = (V, E)$ .

A chaque arc  $e$  du graphe on associe une valeur  $F(e) \in R$ .

Un flot  $F$  est une fonction de  $E$  dans  $R^+$  telle que  $e \rightarrow F_e$  (le flot sur  $e$ ) et :

Un flot de  $S$  à  $T$  est une fonction telle que :

$$\sum_{i \setminus (i,j) \in E} F_{ij} = \sum_{k \setminus (j,k) \in E} F_{jk} \quad \forall j \in V \setminus \{S, T\} \text{ où } F_{ij} = F(i, j) \quad (3.1)$$

Cela signifie que la somme des entrées est égale à la somme des sorties.

La valeur  $F_{ij} = F(i, j)$  est le flot dans l'arête.

Le flot est dit réalisable si pour toute arête  $(i, j) \in E$ , nous avons  $0 \leq F_{ij} \leq w_{ij}$

Le flot est dit saturé si sur tout chemin de  $S$  à  $T$  il existe un arc ayant un flot égal à sa capacité.

Le problème de flot maximum consiste à transporter la quantité maximale possible d'une origine (source) à une destination (puits) donnée sans dépasser les capacités des arcs, donc le problème du flot maximum consiste à déterminer un flot réalisable entre  $S$  et  $T$  qui soit de valeur maximum.

Il existe 3 théorèmes pour calculer le flot maximum, la première est l'algorithme de Ford-Fulkerson [38], elle s'appelle aussi la méthode de marquage dont on cherche une chaîne ou chemin améliorant, c'est-à-dire une succession d'arcs sur lequel nous pouvons augmenter ou diminuer la valeur du flot dans les arcs afin d'améliorer la valeur du flot dans le graphe ou le réseau.

Pour calculer le flot maximal :

- ✓ L'initialisation de la valeur du flot circulant dans le graphe,  $F_{initial} = 0$  : la recherche d'un flot compatible qu'on peut faire

### 3. Les techniques de segmentation

circuler dans le graphe en respectant les contraintes des capacités, nous donnons à tous les arcs du graphe un flot=0.

- ✓ Marquage des sommets : marquer (+) la source  $S$  du graphe, et marquer un sommet qui est l'extrémité d'un arc dont l'origine est déjà marqué (+/-) sur lequel le flot peut augmenter.
- ✓ Marquer (-) un sommet d'un arc qui est origine, et dont l'extrémité est déjà marqué (+/-) sur lequel le flot peut diminuer.
- ✓ Trouver la valeur  $\varepsilon$  pour améliorer le flot tel que  
 $\varepsilon = \min\{\varepsilon^+, \varepsilon^-\} > 0$ ,  $\varepsilon^+ = \min\{w(u) - F(u) \text{ tel que } u \in \Gamma^+(\text{arêtes directrices})\}$ ,  
 $\varepsilon^- = \min\{F(u) \text{ tel que } u \in \Gamma^-(\text{arêtes inverses})\}$ .

#### Algorithme de Ford-Fulkerson

Initialisation du flot à zéro.

**Tant que** le flot n'est pas maximum.

Recherche chaîne augmentante.

S'il n'y a pas de chaîne augmentante, **STOP**.

Augmenter le flot pour cette chaîne.

L'algorithme de Ford-Fulkerson a quelques limites lors de la recherche d'une chaîne améliorante, la procédure ne fait pas discrimination entre les chaînes longues et courtes le choix se fait comme au hasard. Deux chercheurs indépendants ont proposé de modifier l'algorithme à l'étape du choix de la chaîne améliorante ; il en résulte une nouvelle procédure d'Edmonds-Karp et c'est le deuxième algorithme permettant de résoudre le problème de flot maximal.

C'est une implémentation particulière de l'algorithme Ford-Fulkerson en parcours largeur et qui consiste toujours à trouver une chaîne améliorante de plus court chemin de  $S$  à  $T$ , c'est-à-dire celle avec de moins arêtes possibles.



### 3. Les techniques de segmentation

En effet c'est une implémentation à l'identique de l'algorithme de Ford-Fulkerson sauf que le troisième algorithme s'appelle algorithme de Dinic il est semblable à l'algorithme de Edmonds-Karp permettant de diminuer le temps de calcul.

#### 2.7. COUPE DE GRAPHE


Une coupe de graphe valué  $G = (V, E, w)$  possédant un seul sommet  $S$  et un seul sommet puits  $\mathcal{T}$  une partition des sommets en deux sous-ensembles disjoints notée  $(X, \bar{X})$  telle que :

$$\begin{aligned}V &= X \cup \bar{X} \\ X \cap \bar{X} &= \emptyset \\ S \in X \text{ et } \mathcal{T} \in \bar{X}\end{aligned}$$

En optimisation combinatoire, le coût d'une coupe est défini comme la somme des poids des arêtes sortant :

$$|C| = \sum_{e \in C} w_e \quad (3.2)$$


3. Les techniques de segmentation



La capacité de la coupe :  $w(X, \bar{X}) = 5 + 1 + 3 = 9$ .

Figure 3.7 : Coupe de graphe.

Si nous prenons un deuxième exemple de coupe de graphe



La capacité de la coupe  $w(X, \bar{X}) = 10 + 3 + 4 = 17$ .

Figure 3.8 : Exemple de coupe de graphe

## 2.8. THEOREME DE MAX FLOW/MIN CUT

La coupe minimale est la coupe qui a la minimale valeur absolue appelée *min cut*, et elle peut être obtenu en trouvant le *max flow*. Le min cut est l'équivalent du max flow [54]. L'algorithme de min cut/max flow a été développé en 2004 par Boykov and Kolmogorov [52], [48], et peut être utilisé pour obtenir la coupe minimale pour le graphe  $S - \mathcal{T}$ . Donc le graphe est divisé par cette découpe, les nœuds sont séparés en deux sous-ensembles disjoints  $S$  et  $\mathcal{T}$ .

Nous pouvons la définir comme suit : Pour tout graphe, tout couple  $(S, \mathcal{T})$  de sommets du graphe, et pour toute pondération positive, la valeur maximum du flot de  $S$  à  $\mathcal{T}$  est égale à la capacité minimum d'une coupe séparant  $S$  de  $\mathcal{T}$ .

## 2.9. LES COUPES DE GRAPHES NORMALISEES

Dans le procédé de décomposition, nous cherchons à partitionner le graphe en deux ensembles de points  $A$  et  $B$  en séparant les contours connectés en deux parties.

Dans de nombreux problèmes de vision, une des facettes les plus attrayantes des coupes de graphes est la recherche de coupe minimale en calculant :

$$\text{Min Cut } (A, B) = \text{Min } (\text{Cut}(A, B)) \quad (3.3)$$

Les résultats obtenus ont des limites, le modèle favorise le regroupement des points isolés, et accrois le nombre d'arêtes de la coupe tout en entraînant un sur-partitionnement de l'image. Malik et al [46] ont proposé une nouvelle méthode basée sur le même principe, dite normalisée qui supprime l'influence du nombre d'arêtes dans la coupe:

$$NCut(A, B) = \frac{\text{Cut } (A, B)}{\text{Asso}(A, V)} + \frac{\text{Cut } (A, B)}{\text{Asso } (B, V)} \quad (3.4)$$

Avec

$$Asso(A, V) = \sum_{u \in A, t \in V} W(u, t) \quad (3.5)$$

Qui présente la fonction des coûts d'association

Et

$$V = \{A, B\} \quad (3.6)$$

Cette coupe normalisée de graphe vise à trouver une partition (A, B) de ce graphe optimisant une quantité qui assure à la fois la cohérence des pixels de A, celle des pixels de B et la dissimilarité des pixels de A par rapport à ceux de B, tout en évitant le biais vers les petites coupes.

#### 2.10. SEGMENTATION D'IMAGE PAR GRAPH CUT

Plusieurs problèmes de vision par l'ordinateur peuvent être vu comme des problèmes d'étiquetage et pouvant être formulés comme des problèmes de minimisation de l'énergie et la segmentation d'image en fait partie.

Dans la segmentation d'image peut être vue comme un problème de labélisation, où l'image est représentée par un graphe de pixels et nous cherchons à attribuer à chaque pixel une étiquette choisie dans un ensemble prédéterminé.

Soit Le graphe  $G = (V, E)$  où  $V$  est l'ensemble des sommets et  $E$  est l'ensemble des arêtes. Nous distinguons deux nœuds terminaux la source  $S$  et le puits  $T$ . Les autres nœuds sont dits intermédiaires.

Les arcs terminaux  $t-links$  relient un nœud terminal et nœud intermédiaire. Les arcs de voisinage  $n-links$  relient entre eux deux nœuds intermédiaires.

Les nœuds intermédiaires du graphe représentent généralement les pixels d'une image.

### 3. Les techniques de segmentation

Les nœuds terminaux correspondent à l'ensemble des étiquettes qu'il est possible d'assigner aux pixels.

La partition des nœuds des graphes obtenue par une coupe correspond à une segmentation de l'image considérée. Une coupe minimale donne une segmentation optimale par rapport aux propriétés décrites par le poids des arcs. Assigner un poids faible à un arc c'est le rendre attractif pour la constitution d'une coupe minimale. La segmentation consiste finalement à rechercher la coupe d'énergie  $E$  minimum, ce qui est équivalent à rechercher le flot maximum de la source au puits, un problème soluble en un temps polynomial selon le théorème de Ford et Fulkerson.

Nous présentons ici la segmentation d'image en utilisant l'approche proposée par Boykov et al [42]. C'est la segmentation au niveau du pixel, le poids d'un  $n$ -link correspond à une pénalité de discontinuité entre pixels. Le poids d'un  $t$ -link correspond à une pénalité engendrée par le fait d'assigner au pixel l'étiquette correspondant à l'autre nœud terminal.

L'étiquetage se fait au niveau du pixel, lors de la construction du graphe, nous créons un nœud pour chaque pixel  $\mathbf{p}$  à étiqueter.

Soit la fonction d'étiquetage  $f = (f_p)_{p \in P}$  tel qu'à tout pixel  $\mathbf{p}$  de l'ensemble  $P$  des pixels à étiqueter associé une étiquette  $f_p = f(\mathbf{p})$  appartenant à l'ensemble  $\mathcal{L}$  des étiquettes possibles.

Dans le cas d'un graphe  $G = (V, E)$  avec deux nœuds terminaux une source  $S$  et un puits  $\mathcal{T}$ , l'ensemble des pixels à étiqueter vaut  $P = V \setminus \{S, \mathcal{T}\}$ .

Les deux nœuds terminaux  $S$  et  $\mathcal{T}$  sont respectivement associés à 0 et 1, les deux seules étiquettes possibles avec  $\mathcal{L} = \{0, 1\}$ .

La segmentation d'image est de minimiser l'énergie donnée par la formule suivante

$$E(f) = E_{données}(f) + E_{liassage}(f) \quad (3.7)$$

$E(f)$ : est la fonction d'énergie, elle est composé de deux termes, le premier est un terme d'attaches aux données. Il s'écrit :

### 3. Les techniques de segmentation

$$E_{données}(f) = \sum_{p \in P} D_p(f_p) \quad (3.8)$$

La fonction  $D_p(\cdot)$  est une fonction de pénalité qui représente l'attache aux données, c'est-à-dire pour chaque nœud, elle indique dans les quelles mesure l'étiquetage correspond aux données observées. Par exemple nous pouvons utiliser les intensités des graines pour étudier l'intensité de distribution dans l'histogramme pour séparer l'objet du fond [42].

Le terme  $D_p$  peut s'écrire :

$$D_p("obj") = -\ln pr(I_p / "obj") \quad (3.9)$$

$$D_p("fond") = -\ln pr(I_p / "fond") \quad (3.10)$$

Où

$I_p$  et  $I_q$  sont les niveaux de gris des pixels  $p$  et  $q$ .

$pr(I_p / "obj")$  est la probabilité que le pixel  $p$  appartienne à la classe « objet ».

$pr(I_p / "fond")$  est la probabilité que le pixel  $p$  appartienne à la classe « fond ».

Plus la valeur de  $D_p(f_p)$  est élevée, plus il est coûteux d'associer l'étiquette  $f_p$  au nœud  $P$ , et donc moins l'étiquette  $f_p$  soit celle qu'il convient d'assigner à  $p$ .

Le second terme est un terme de régularisation. Il s'écrit généralement

$$E_{lissage}(f) = \sum_{\{p,q\} \in C} B_{p,q}(f_p, f_q) \quad (3.11)$$

Avec  $C = \{\{p, q\} \subset P : (p, q) \in N\}$ , où  $N$  est l'ensemble des  $n$ -links, c'est-à-dire  $E$  privé de l'ensemble de  $t$ -links.

### 3. Les techniques de segmentation

$B_{p,q}$  : est un terme de régularisation portant sur les pixels voisins, on l'appelle aussi potentiel d'interaction, ce terme incite une paire de nœuds voisins à prendre la même étiquette.

Le terme de régularisation peut s'écrire sous la forme :

$$B_{p,q}(f_p, f_q) = \lambda A_{p,q}(f_p, f_q)T(f_p \neq f_q) \quad (3.12)$$

Où

$A(\cdot)$  : est la fonction d'interaction.

$$T(f_p \neq f_q) = \begin{cases} 1 & \text{si } f_p \neq f_q \\ 0 & \text{sinon} \end{cases} \quad (3.13)$$

$\lambda$  : est un paramètre réel positif ou nul, qui règle la pondération relative du terme de lissage par rapport au terme d'attache aux données.

$$\forall (\mathbf{p}, \mathbf{q}) \in N, B_{p,q}(f_p, f_q) = \frac{\lambda}{\text{dist}(\mathbf{p}, \mathbf{q})} \exp\left(-\frac{\|I_p - I_q\|^2}{2\sigma^2}\right) \cdot T(f_p \neq f_q) \quad (3.14)$$

Où

$\text{dist}(\mathbf{p}, \mathbf{q})$  est la distance euclidienne entre  $\mathbf{p}$  et  $\mathbf{q}$ .

$\sigma$  est un paramètre lié au bruit d'acquisition qui contrôle l'affinité de teinte des pixels.

### 3. L'ALGORITHME ISODATA

La deuxième approche que nous décrivons dans ce chapitre est la technique de seuillage automatique (ISODATA), qui constitue une étape essentielle dans notre projet qui occupe une partie sur lequel s'appuie notre contribution.

C'est une technique simple et robuste de segmentation d'image, qui donne des résultats significatifs.

### 3.1. LE SUILLAGE

Les techniques de seuillage sont des techniques très puissantes et très répandues dans le domaine de la segmentation d'image et largement utilisé grâce à de leurs simplicités et leurs efficacités.

Le seuillage a pour objectif de segmenter l'image en deux (ou plusieurs) classe, et consiste à effectuer une partition de l'histogramme en niveaux de gris en utilisant un (ou plusieurs) seuil, et à assigner à chaque pixel la classe la plus proche auquel il appartient et sur l'utilisation du contraste des différents contours détectés.

Tout le problème de seuillage consiste alors à chercher la valeur du seuil dans l'histogramme afin de séparer un objet du fond.

### 3.2. SEGMENTATION D'IMAGE PAR CLASSIFICATION

La segmentation par classification est l'une des procédures les plus utilisées en traitement d'images. Elle identifie les classes des pixels présentent dans l'image et affecte à chaque pixel une étiquette indiquant la classe à laquelle il appartient [58], [59].

Une segmentation optimale par seuillage nécessite donc une localisation optimale des seuils, de segmentation dans l'histogramme. En partant de l'hypothèse du seuillage, si l'histogramme possède plusieurs modes (pics), les seuils optimaux sont situés entre ces derniers.

Cependant dans la pratique ce cas de figure ne se présente pas fréquemment, ce qui rend l'opération de segmentation plus complexe, (par exemple dans le cas où l'histogramme possède un seul mode).

Afin de résoudre ce problème des seuils optimaux, plusieurs méthodes ont été proposées, la plupart de ces méthodes de classification sont les méthodes de classification supervisée et la classification non supervisée.

Dans les méthodes de classification supervisées (dirigées), les classes sont définies par des connaissances à priori, comme l'étude de



### 3. Les techniques de segmentation

l'histogramme des niveaux de gris. L'objectif est de regrouper des pixels dont on connaît la nature et qui sont semblables à des objets de référence (comme par exemple régions d'intérêts).

Les méthodes de classification non supervisées (non dirigées):le but est de partitionner l'image sans aucune connaissance à priori et les classes sont créées automatiquement. Le principe consiste à réaliser des groupements de pixels en se basant sur la "proximité" des informations numériques qui leurs sont propres(le niveau de gris, la position des points).

La segmentation par seuillage d'histogramme constitue un cas particulier de la segmentation par classification, elle répartit les pixels en classe en fonction de leurs niveau de gris, et les délimiter par des seuils.

Elle consiste à répartir les pixels en  $n$  classe  $(n_1, n_2, \dots, n_k)$  à partir d'un ensemble de seuils  $T = \{t_1, t_2, \dots, t_{k-1}\}$

Soit  $f$  l'image original et  $g$  l'image segmentée, la classification de chaque pixel est définie par :

$$g(x, y) = k \quad \text{si} \quad t_n \leq f(x, y) \leq t_{n+1} \quad \text{pour} \quad n = 0, \dots, n - 1$$

Où  $(x, y)$  sont les coordonnées du pixel,  $k$  est le nombre de classe, et  $T = \{t_1, t_2, \dots, t_{n-1}\}$ , sont les différents seuils de segmentation.

Si  $f(x, y) < T$  le pixel étiqueté fond.

Si  $f(x, y) \geq T$  le pixel étiqueté objet.

Dans ce cas on parle du seuillage simple « binarisation ».

Si le nombre de seuils recherché est supérieur à 1, nous parlons de multi seuillage (classification).

Le seuillage d'une image peut se faire soit par seuillage manuel soit par seuillage automatique

Le seuillage manuel d'une image comporte 4 étapes :

1. Observation de l'histogramme de l'image.

### 3. Les techniques de segmentation

2. Choix des seuils dans les vallées.
3. Définition des classes des régions par intervalle de couleurs
4. Classement des pixels.

Le seuillage automatique permet de trouver la valeur du seuil recherché d'une façon automatique.

Il en existe plusieurs méthodes pour calculer la valeur du seuil à appliquer. L'une des plus répandue est la méthode d'ISODATA.

Afin de déterminer l'appartenance d'un pixel à une classe, nous utilisons la méthode de classification non supervisées: ISODATA.

ISODATA est une technique de segmentation d'image par classification non supervisée, c'est une version amélioré de l'algorithme K means, a été introduite pour la première fois par Velasco en 1980 [18] comme une référence de qualité dans cette analyse. En effet ISODATA est un algorithme classique qui permet d'effectuer une très bonne catégorisation qu'il peut être traité comme une cible de qualité à atteindre.

Elle se base particulièrement sur l'histogramme des niveaux de gris. L'objectif est donc de trouver des seuils, qui permettent de séparer l'histogramme en classes itérativement.

Cette méthode fait partie des techniques de seuillage global, donc par conséquent ça permet de déterminer les seuils globaux en ne nécessitant en premier terme que le choix initial des valeurs moyennes associés à chacune des  $n$  classes.

Ils existent plusieurs versions de cette méthode. A l'origine, elle est utilisée avec l'histogramme mais elle peut être adaptée pour être utilisée directement avec les échantillons ordrés. La taille de signal, les échantillons du signal sont  $[x(1), \dots, x(N_n)]$ . Les étapes de l'algorithme sont comme suit :

1. L'état initial (itération  $i = 0$ ),  $seuil_0 = x(\frac{N_n}{2})$ , c'est-à-dire que  $n_0$ , la position du seuil initial, est posée à  $\frac{N_n}{2}$ .

### 3. Les techniques de segmentation

2.  $i = i + 1$ .

3. Nous calculons les moyennes :

$$m_i^{(bas)} = \text{moyenne de } [x(1) \dots x(n_{i-1})]$$

et

$$m_i^{(haut)} = \text{moyenne de } [x(n_{i-1} + 1) \dots x(N_n)].$$

4. La nouvelle valeur du seuil est alors :  $seuil_i = \left(\frac{m_i^{(bas)} + m_i^{(haus)}}{2}\right)$

5. Nous cherchons la valeur  $n_i$  tel que  $x(n_i) \leq seuil_i \leq x(n_i + 1)$ .

6. Si  $n_i \neq n_{i-1}$ , retour à l'étape 2, sinon nous nous arrêtons et la valeur du seuil est :

$$seuil = x(n_i).$$

La figure 3.9 présente un exemple d'une image cérébrale segmentée en utilisant l'algorithme de seuillage itératif ISODATA.




Figure 25 : exemple seuillage ISODATA (classification).

(a). image à segmenter. (b) résultat de segmentation

### 3. Les techniques de segmentation

#### 4. CONCLUSION

Nous avons présenté dans ce chapitre deux approches, nous avons commencé par la théorie de coupe de graphe d'une manière simple dont le but de définir et introduire à la segmentation d'image en utilisant cette théorie avec un enchaînement des principaux étapes. Cette technique s'appuie sur l'algorithme de min cut / max flow qui est très bien réputé notamment pour la segmentation interactive des images en se basant sur le principe de la minimisation de l'énergie. C'est une technique optimale qui cherche à trouver le bon compromis entre le terme de région et frontière.

Dans un second temps, nous avons détaillé un algorithme de seuillage automatique de l'image ISODATA, qui nous nous sommes particulièrement intéressés. Elle a plusieurs versions et sert à segmenter l'image d'une façon automatique en se basant sur l'histogramme de l'image. Cette approche nous allons nous en servir d'une façon primordiale dans le chapitre suivant.

# 4

## SEGMENTATION INTERACTIVE D'IMAGES CÉRÉBRALES EN COMBINANT LE SEUILLAGE AUTOMATIQUE ET LA COUPE DES GRAPHES

### 1. INTRODUCTION

Les tumeurs cérébrales doivent être détectées dès leurs premiers stades afin de pouvoir contrôler leurs évolutions et offrir une chance de guérison aux patients.

Il s'agit donc de développer des méthodes de segmentation capables de séparer les zones tumorales (composées de la ou des tumeurs et d'éventuels œdèmes) des structures anatomiques saines (principalement la matière blanche, la matière grise et le liquide céphalo-rachidien).

Un système de segmentation capable de fournir des résultats quantitatifs sur les tumeurs est nécessaire.

La segmentation est une application de l'analyse d'image qui donne souvent des résultats très variables selon le type et la qualité d'image.

Le développement des approches de segmentation automatiques des tumeurs cérébrales est techniquement difficile, parce que les zones de lésions sont affectées par des changements d'intensité qui sont relatives aux tissus normaux.

#### 4. Segmentation interactive par l'approche hybride

En raison de sa pertinence clinique élevée et son caractère difficile, le problème de la segmentation des tumeurs cérébrales a attiré une attention considérable au cours des 20 dernières années, résultant en une multitude de différents algorithmes pour automatiser la segmentation semi-automatique et interactive de structures tumorales.

La segmentation interactive d'images est devenue un domaine important en vision par ordinateur. Nous utilisons actuellement ce type d'approche pour contourner le problème de segmentation automatique qui ne donne pas toujours des résultats satisfaisants et fiables.

Elle permet de séparer d'une manière précise des entités d'une image. Elle exploite les suggestions de l'utilisateur, qui interagit en sélectionnant les zones d'intérêts au moyen d'un programme, en réalisant des cliques sur l'image ciblée.

Dans le cas de la segmentation interactive binaire d'une image, nous cherchons à séparer un objet du fond, L'idée générale est de laisser l'opérateur définir manuellement des régions « graines » qui appartiennent à l'objet et au fond [62].

Nous attribuons respectivement 1 pour l'objet et 0 pour le fond pour les séparer, ce n'est pas le cas pour la segmentation interactive non binaire qui est en général un problème d'étiquetage, d'une classification multi étiquette, qui va de 1 jusqu' à n, l'étiquette peut présenter à titre d'exemple un indice de couche dans le cas de la segmentation en couches de mouvement ou une disparité dans le cas de stéréovision.

Dans ce chapitre nous présentons un algorithme de segmentation basé sur la combinaison des deux méthodes cités précédemment : le seuillage automatique en appliquant la technique de classification *ISODATA* et le *Graph cut* basé sur l'approche *min cut /max flow* proposée par Boykov et Jolly [48], dans le but d'améliorer la qualité de la segmentation.

Nous avons commencé par appliquer le seuillage automatique utilisé comme technique de pré-segmentation de l'image cérébrale. Cette approche prépare l'image et offre une classification qui permet de

#### 4. Segmentation interactive par l'approche hybride

mettre en évidence les zones d'intérêts qui seront plus claires et plus intéressantes, par la suite nous avons appliqué l'algorithme de *max flow/min cut*. Les résultats de segmentation finale sont très prometteurs et ne dépendent pas du paramètre  $\lambda$ .

## 2. ALGORITHME HYBRIDE

Nous avons combiné la méthode de *Graph cuts* et la segmentation par classification automatique d'histogramme (*ISODATA*) dans le but de guider et améliorer le processus de segmentation. Les premières applications de la méthode de *Graph cuts* ont montré que le minimum de l'énergie obtenu est en général meilleur en le comparant avec les techniques classiques [82].

Notre objectif est d'analyser la nouvelle approche hybride de la segmentation interactive des images cérébrales, l'image segmentée est divisée en deux parties :

- 1- « L'objet » qui représente dans notre cas la tumeur présente dans l'image cérébrale.
- 2- « Le fond » qui représente le reste de l'image cérébral.

### 2.1. ALGORITHME ISODATA

C'est une technique de segmentation d'image par classification non supervisée (qu'on appelle aussi seuillage itératif ou multi-seuillage automatique), elle a été proposée par Ball et Hall [60], son principe est d'attribuer automatiquement chaque pixel à une classe suivant sa signature spectrale, cet algorithme décrit en [18] utilise de multiples itérations.

L'algorithme *ISODATA* possède à l'état initial des classes arbitrairement construites, et les pixels sont attribués à la classe la plus proche. La moyenne de chaque classe est calculée sur la base des nouveaux pixels assignés à la classe.

- Etape 1 : Une classe peut être détruite si elle ne comporte pas suffisamment d'objets.

#### 4. Segmentation interactive par l'approche hybride

- Etape 2 : Les classes sont regroupées si le centre de deux classes est plus proche qu'un certain seuil, autrement dit : deux classes peuvent être agglomérées si la distance entre leurs centres est inférieure à un seuil donné
- Etape 3 : Une classe peut être scindée en deux si la dispersion des objets la constituant est supérieure à un seuil donné.

La seconde et la troisième étape sont répétées jusqu'à ce que les changements entre les itérations soient minimales.

Après cette phase automatique une interprétation visuelle est requise pour assigner à chaque classe une description cohérente, et éventuellement regrouper manuellement les classes superflues.

Nous commençons par déterminer l'intervalle  $[min\ max]$  de valeurs non-nulles de l'histogramme, en suite nous estimons des valeurs moyennes initiales en divisant l'intervalle  $[min\ max]$  en deux parties équidistantes, puis nous prenons  $m_1$  et  $m_2$  comme les moyennes arithmétiques de chaque classe si la densité de probabilité était uniforme entre  $min$  et  $max$ .

Les  $n-1$  seuils  $T_i$  sont évalués en utilisant la relation suivante :

$$T_i = \frac{m_i + m_{i+1}}{2}, \quad i = 1, \dots, n - 1 \quad (4.1)$$

A chaque itération nous calculons le seuil  $T$  en prenant l'entier le plus proche de la moyenne des deux moyennes, puis nous mettons à jour les moyennes en calculant la moyenne statistique pour chaque classe :

$$T = \frac{m_1 + m_2}{2} \quad (4.2)$$

$$m_1 = \frac{\sum_{j=min}^T j \times h(j)}{\sum_{j=min}^T h(j)} \quad (4.3)$$



$$m_2 = \frac{\sum_{j=T+1}^{max} j \times h(j)}{\sum_{j=T+1}^{max} h(j)} \quad (4.4)$$

Nous recalculons les seuils et les moyennes jusqu'à ce qu'il n'y ait plus aucun changement, moment où l'algorithme converge.

## 2.2. L'ALGORITHME GRAPH CUT

La deuxième approche que nous avons adoptée est l'algorithme de la coupe des graphes (GRAPH CUT), cet algorithme a été déjà décrit dans le chapitre 3.

En appliquant la théorie des graphes sur les images, l'idée directrice est de créer un graphe  $G = (V, E, w)$  à partir de l'image, en se basant sur le modèle établi par Boykov et Jolly [48], c'est une méthode de segmentation très efficace dans le cas de l'interaction avec l'utilisateur.

Cette méthode repose sur les graphes de voisinage, où chaque pixel de l'image à segmenter (cet ensemble noté  $P$ ) devient un nœud du graphe et les arêtes issues de ce nœud rejoignent les nœuds représentant les pixels voisins. L'objectif de la segmentation est d'attribuer à chaque pixel, une classe  $w$ , pouvant être soit  $O$  si le pixel considéré appartient à l'objet, soit  $B$  s'il appartient au fond.

La source  $S$  représente l'objet  $O$  et le puits  $\mathcal{T}$  représente le fond  $B$ . chaque couple de nœud  $(p, q) \in \mathcal{V}^2$  dans un voisinage  $\mathcal{N}$  est connecté par un segment appelé  $n-link$ . Chaque nœud  $p \in \mathcal{V}$  est connecté aux nœuds terminaux  $S$  et  $\mathcal{T}$  par deux segments respectifs appelés  $t-links$ .

La coupe d'un lien  $t-link$  de  $p$  vers  $S$  (respectivement  $\mathcal{T}$ ) permet d'attribuer l'étiquette  $O$  (respectivement  $B$ ) à ce pixel définissant ainsi une segmentation de l'image, comme le montre la figure 4.1. Nous associons pour chaque  $n-link$  et  $t-link$  un poids non négatif. Une coupe divise les nœuds d'un graphe en deux partitions correspondants à une segmentation d'image en deux régions « *Objet* » et « *Fond* » avec des propriétés topologiques arbitraires.

#### 4. Segmentation interactive par l'approche hybride

La capacité ou le coût de la coupe  $C$  est donnée par la somme des poids des segments  $n$ -links et  $t$ -links.

La meilleure segmentation de l'image est obtenue en calculant la coupe de coût minimum.

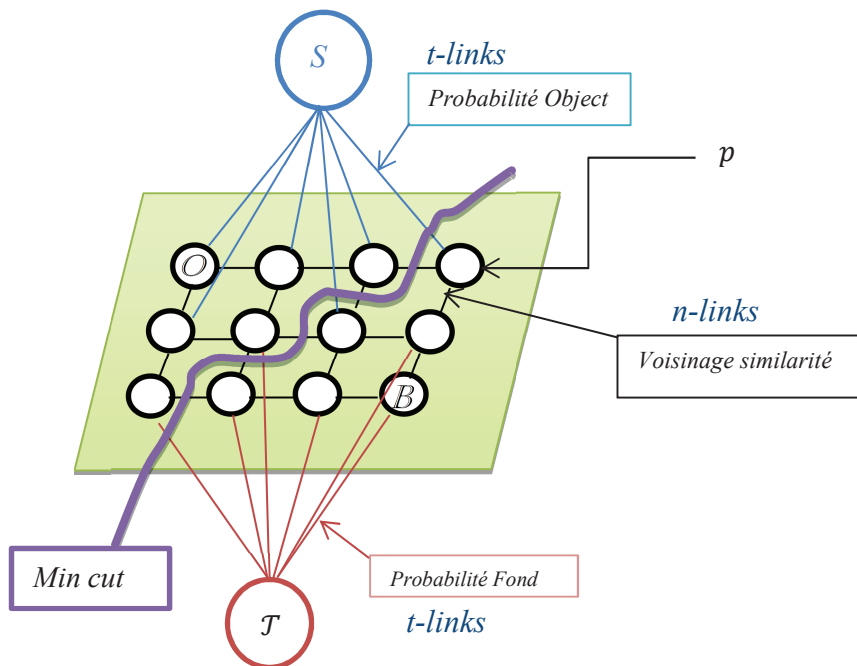


Figure 4.1 : coupe de graphe min cut sur une image de 3x4.

Soit  $I_p$  le niveau de gris du pixel  $p$ , les  $t$ -links entre un pixel  $p$  et les deux nœuds terminaux  $S$  et  $T$  sont pondérés par un terme dit terme de région, noté  $R_p$  et défini par :

$$R_p(w) = -\ln Pr\left(\frac{I_p}{w}\right) \quad (4.5)$$

Où  $Pr\left(\frac{I_p}{w}\right)$  est la probabilité que le pixel  $p$  appartienne à la classe  $w$ , généralement elle est obtenue par un histogramme sur les niveaux de gris de l'objet et du fond [55] comme le montre la figure 4.2.

#### 4. Segmentation interactive par l'approche hybride




Figure 4.2: Répartition des niveaux de gris des pixels selon la classe objet ou la classe fond.

Le terme régularité ou énergie contour est attribué aux  $n$ -links conçu pour assurer la cohérence spatiale dans un voisinage de pixels. Ce terme est noté par  $B_{p,q}$  et défini comme suit :

$$B_{p,q} \propto (\text{proportionnel à}) \exp\left(-\frac{(I_p - I_q)^2}{2\sigma^2}\right) \cdot \frac{1}{\text{dist}(p,q)} \quad (4.6)$$

Où  $I_p$  et  $I_q$  sont les niveaux de gris des pixels  $p$  et  $q$ .

$\text{dist}(p, q)$  est la distance euclidienne entre  $p$  et  $q$ .

$\sigma$  est une constante liée au bruit d'acquisition qui contrôle l'affinité de teinte des pixels, l'information qui apporte la mesure  $\exp\left(-\frac{(I_p - I_q)^2}{2\sigma^2}\right)$  permet de discriminer les objets non semblables par la différence de teinte, tandis que  $\frac{1}{\text{dist}(p,q)}$  évalue les proches voisins des pixels par leur distance. Dans une région uniforme,  $I_p$  et  $I_q$  sont similaires donc :

#### 4. Segmentation interactive par l'approche hybride

$|I_p - I_q| < \sigma$  ce qui donne une grande valeur de  $B_{p,q}$  c'est-à-dire une forte similarité entre les pixels voisins, et par conséquent dissuade toute coupe de graphe dans ce voisinage.

Au contraire dans une région non uniforme c'est-à-dire une zone de contour,  $I_p$  et  $I_q$  sont différents donc :  $|I_p - I_q| > \sigma$  ce qui donne une faible valeur de  $B_{p,q}$  et une faible similarité entre les pixels voisins en favorisant une coupe de graphe en résultant la segmentation d'image.

Dans la méthode classique décrite par Boykov et Jolly [48], l'utilisateur sélectionne des pixels de l'objet et des pixels des fonds, ils sont appelés les graines. Ces pixels sont reliés aux nœuds terminaux. La valeur de  $t$ -links doit être suffisamment grande pour s'assurer qu'ils ne fassent pas partie de la coupe.

La segmentation d'image par la méthode de coupe de graphe peut être considérée comme un problème de minimisation de l'énergie, et par conséquent l'objectif est de trouver une coupe optimale de graphe donnant une segmentation satisfaisante, donc cette coupe permet de minimiser une fonction de la forme suivante :

$$E(C) = \lambda \sum_{p \in V} R_p(w_p) + \sum_{p,q \in \mathcal{N}} B_{p,q} \cdot \delta(w_p \neq w_q) \quad (4.7)$$

$$\text{Tel que } |\delta(w_p \neq w_q)| = \begin{cases} 1 & \text{si } w_p \neq w_q \\ 0 & \text{sinon} \end{cases} \quad (4.8)$$

Cette énergie est équivalente au flot maximum de la source au puits.

Nous pouvons calculer la capacité  $w_p$  de l'objet  $O$  ou du fond  $B$ .

$$\text{La capacité } w_{\text{classe\_objet}} = \begin{cases} k & \text{si } I \in I_{\text{Objet}} \\ 0 & \text{si } I \in I_{\text{Fond}} \\ \lambda \cdot w_{\text{objet}}(I) & \text{dans les autres cas} \end{cases} \quad (4.9)$$

#### 4. Segmentation interactive par l'approche hybride

$$\text{Tel que } w_{classe\_Objet} = -\lambda \ln Pr \left( \frac{I_p}{w_{Objet}} \right) \quad (4.10)$$

$$\text{La capacité } w_{classe\_Fond} = \begin{cases} 0 & \text{si } I \in I_{Objet} \\ k & \text{si } I \in I_{Fond} \\ \lambda \cdot w_{Fond}(I) & \text{dans les autres cas} \end{cases} \quad (4.11)$$

$$\text{Tel que } w_{classe\_Fond} = -\lambda \ln Pr \left( \frac{I_p}{w_{Fond}} \right) \quad (4.12)$$

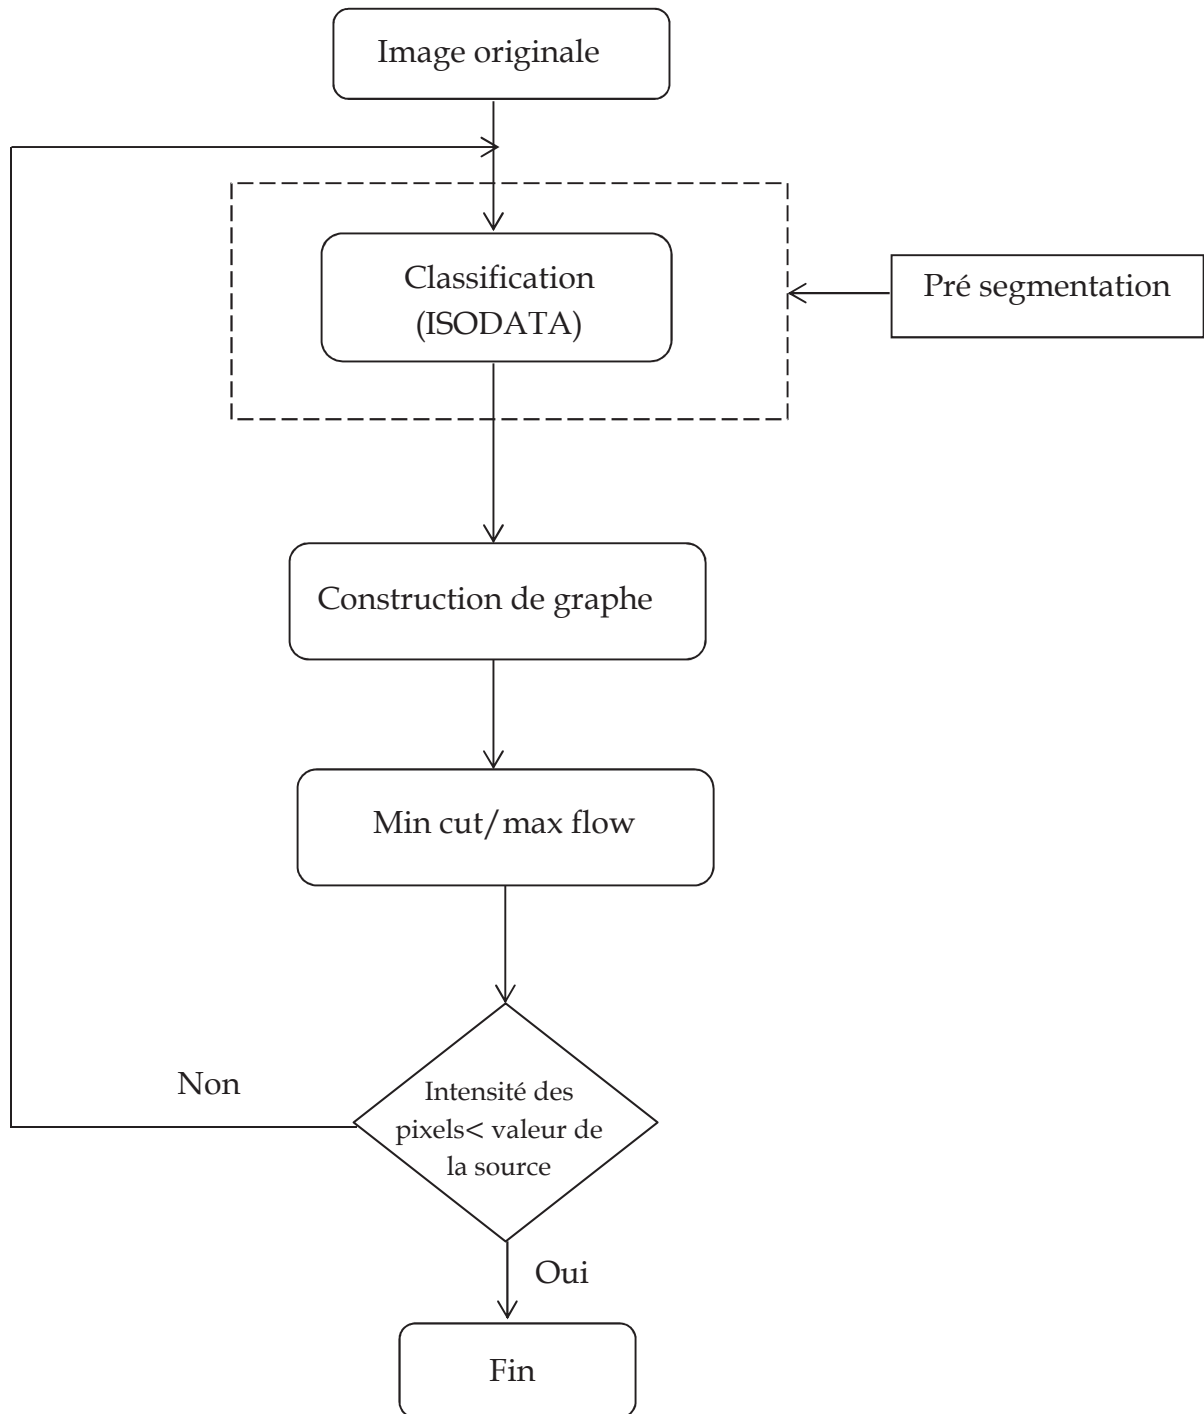
$$k = 1 + \max_{p \in V} \sum_{q: \{p,q\} \in \mathcal{N}} w_{p,q} \quad (4.13)$$

$\lambda$  : est un paramètre réel positif ou nul, qui règle la pondération relative du terme de lissage par rapport au terme d'attache aux données. Plus le paramètre  $\lambda$  est élevé, plus il devient coûteux de couper des *n-links*, ce qui encourage à n'en couper qu'un faible nombre et donc à obtenir des régions de segmentation plus grandes et des frontières plus régulières.

Pour procéder à notre algorithme hybride[82], nous avons présentons l'organigramme suivant :

#### 4. Segmentation interactive par l'approche hybride

**Algorithme hybride :**



#### 4. Segmentation interactive par l'approche hybride

La segmentation finale par l'approche hybride est composée de plusieurs étapes :

Le prétraitement de l'image cérébrale qui contient une tumeur où cette pathologie existante ne représente qu'une petite partie de l'image (l'objet). Nous appelons cette phase par étape de pré-segmentation afin de déterminer le plus précisément possible les intensités de l'objet et du fond. Nous avons utilisé *ISODATA* qui est un algorithme de classification pour une initialisation qui sert à une pré-segmentation de l'image dans le but de préparer l'image et favoriser la segmentation.

Pour se faire nous commençons par la définition de l'histogramme, qui est un graphique statistique permettant de présenter la distribution des intensités des pixels d'une image, c'est-à-dire le nombre de pixels pour chaque intensité lumineuse. L'histogramme représente le niveau d'intensité en abscisse en allant du plus foncé à gauche au plus clair à droite. La classification basée sur l'algorithme *ISODATA* consiste à déterminer le seuil optimal pour classifier l'image en plusieurs classes suivant le niveau de gris de chaque pixel. Séparer itérativement l'histogramme en deux classes (fond) et (objet) qui seront par la suite posées comme la valeur de la source  $S$  et du puits  $T$ .

Le seuillage itératif est utilisé dans le but de préparer l'image et par conséquent bien cibler les pixels appartenant à la source (l'objet), et ça permet aussi à les mettre en évidence avec plus de précision. L'intégration de l'algorithme *ISODATA* pour effectuer une pré-segmentation permet non seulement de séparer l'image en deux ensembles l'objet et le fond, mais aussi de dégager une valeur pour la source et le puits.

Dans les approches de segmentation de l'image basées sur le *Graph cuts*, le paramètre  $\lambda$  est utilisé pour contrôler et équilibrer l'importance relative entre les deux termes (terme des données et terme de lissage).

Le standard algorithme *Graph cuts* permet la segmentation finale de l'image. En effet dans l'approche proposée par Boykov et al [61], ils ont montré que le paramètre  $\lambda$  joue un rôle très important, il a un grand effet sur les résultats de segmentation, et que le choix judicieux du paramètre  $\lambda$  contribue à la bonne qualité de la segmentation d'image.

#### 4. Segmentation interactive par l'approche hybride

Plusieurs travaux ont été publiés [18], [64] et qui traitent ce problème.

Les algorithmes de *Graph cuts* standard, donne des résultats de segmentation d'images qui dépendent de la valeur de  $\lambda$ , et par conséquent différentes valeurs de  $\lambda$  donnent différents résultats de segmentation pour la même image.

Pour une segmentation basée sur le terme frontière uniquement où le paramètre  $\lambda$  est nul, ne donne aucun résultat, c'est le flot nul qui circule dans le graphe (voir Figure.4.3 (b)).

Pour différentes images données, une valeur fixe de  $\lambda$  ne peut pas donner une segmentation satisfaisante. Depuis les valeurs  $\lambda$  appropriées varieront largement entre les différentes images, l'utilisateur peut avoir à dépenser une quantité importante de temps pour trouver la valeur idéale de  $\lambda$  correspondante à chaque image.

Dans les travaux récents de la littérature [62], beaucoup d'efforts ont été faits pour la sélection optimale de  $\lambda$ .

Sachant que pour les faibles valeurs de  $\lambda$ , nous avons une sur segmentation de l'image, et pour des valeurs plus grandes de  $\lambda$ , une sous segmentation ont tendance à se produire (Fig.4.3).

Nous pouvons fixer des valeurs de  $\lambda$  appropriées pour chaque image spécifique.



#### 4. Segmentation interactive par l'approche hybride




Figure 4.3: segmentation d'images en appliquant l'algorithme de Graph cuts.

(a) : image originale, (b) image segmenté en utilisant l'algorithme standard *graph cut* avec  $\lambda=0$ , (c) image segmentée  $\lambda=1$ , (d) image segmentée  $\lambda=2000$ , (e) image segmentée  $\lambda=50$ .

#### 4. Segmentation interactive par l'approche hybride




Figure 4.4 : segmentation d'images en appliquant l'algorithme de Graph cuts.

(a) image originale. (b) image segmentée en utilisant l'algorithme standard *graph cut* avec  $\lambda=10$ . (c) image segmentée en utilisant l'algorithme standard *graph cut* avec  $\lambda= 290$ . (d) image segmentée en utilisant l'algorithme standard *graph cut* avec  $\lambda= 300$ .

Habituellement,  $\lambda$  est fixé à une certaine valeur par les développeurs de l'algorithme de segmentation, et il est prévu de donner des résultats de segmentation satisfaisants pour les images similaires à celles qui ont été utilisés pour ajuster les paramètres. Mais, lors d'une autre classe d'images, les résultats pourraient être médiocres. Donc pour de meilleures performances,  $\lambda$  doit être estimé pour chaque image séparément.

De nos expériences, le paramètre  $\lambda$  était plus facile à fixer par notre méthode et apporte donc beaucoup d'avantages pour les utilisateurs

#### 4. Segmentation interactive par l'approche hybride

dans les applications réelles. En combinant le multi seuillage automatique avec l'algorithme standard de *graph cut* proposé par Boykov et al [48], les résultats obtenus sont prometteurs et nettement satisfaisants.

Pour  $\lambda=0$  nous n'avons obtenu aucun résultat de segmentation, c'est l'image originale qui s'affiche, ce qui correspond à un flot nul qui circule dans l'image, et pour le reste même pour une valeur très faible ou très élevée de  $\lambda$  le résultat de la segmentation ne change pas avec des résultats très satisfaisants et même nettement meilleurs que les résultats obtenus en utilisant le standard algorithme de *graph cut* proposé par Boykov [48] (Fig.4.5).




Figure 4.5 : Segmentation d'image en appliquant l'approche hybride.

(a) image originale, (b) image segmentée en utilisant notre approche avec  $\lambda=0.01$ , (c) image segmentée en utilisant notre approche avec  $\lambda=2000$ .

Pour plus d'exemple nous présentons dans le tableau.4.1 une comparaison entre les résultats obtenus par Boykov et al, et ceux obtenus en utilisant notre approche.

#### 4. Segmentation interactive par l'approche hybride

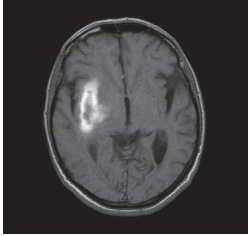


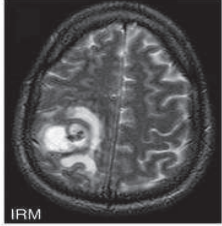
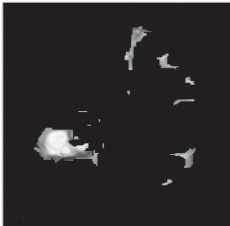
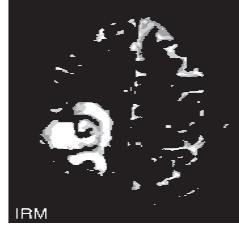
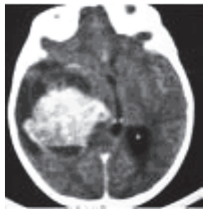
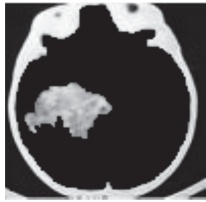

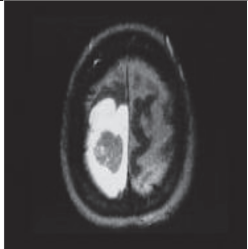


	(a)	(b)	(c)
1			
2			
4			
5			

Tableau 4.1 : Comparaison des résultats de segmentation

(a) image originale, (b) images segmentées en utilisant l'algorithme standard *graph*, (c) résultat final de segmentation en combinant le seuillage itératif avec l'algorithme de *graph cut*.

#### 4. Segmentation interactive par l'approche hybride

Nous pouvons remarquer la performance de notre méthode et la précision des résultats obtenus, sans que le paramètre  $\lambda$  ait une influence sur le résultat de segmentation, et par conséquent éviter la sur segmentation et la sous segmentation de l'image, et un vrai gain du temps que nous pouvons le perdre en cherchant la valeur correspondante du paramètre  $\lambda$ .

En cas de faible contraste :




Figure 4.6 : comparaison de segmentation d'une image à faible contraste

(a) et (d). (b), (e) segmentation en utilisant l'algorithme de Boykov et al. (c), (f) segmentation de l'image en utilisant notre approche.

Nous notons que pour notre approche il y a un lissage parfait de la partie segmentée même en cas de faible contraste en comparant avec celle de Boykov et al. Nous notons aussi que segmenter une image avec un niveau de gris supérieur (plus clair) que la zone d'intérêt (la lésion

#### 4. Segmentation interactive par l'approche hybride

cérébrale) est très difficile de garder seulement la lésion sans les bordures comme c'est montré dans l'image figure.4.6 (d), mais notre algorithme a réalisé ce défi avec succès, voir figure.4.6 (f).

En revanche il existe un cas et d'ailleurs c'est presque le même problème pour les algorithmes de segmentation interactive basés sur le *graph cuts* pose des limites, quand il s'agit des zones qui ne sont pas des zones d'intérêts mais qu'elles ont la même valeur de pixels que les objets d'intérêts, dans ce cas nous pouvons avoir une segmentation d'image avec d'autres objets intrus, parce que ces derniers sont signalés comme des objets d'intérêt en portant la même valeur des niveaux de gris des pixels (figure 4.7).




Figure 4.7 : Exemple de la limite de l'algorithme.

(a) image cérébrale avec astrocytome cérébelleux kystique, (b) segmentation de la tumeur.

Par contre ça n'influe pas sur notre concept et le paramètre n'a aucune influence sur le résultat de l'image.

### 3. CONCLUSION

Nous avons cité dans ce chapitre deux approches de segmentation de l'image cérébrale, la première est le seuillage itératif (ISODATA), qui a facilité la tâche de bien identifier les zones d'intérêts. La seconde est l'algorithme standard *graph cuts* proposé par Boykov et al, où nous avons montré l'intérêt de min cut / max flow dans un graphe qui mène au final à résoudre un problème de minimisation d'énergie pour la segmentation d'image.

La combinaison des deux techniques donne des résultats très intéressants. Le seuillage itératif permet de mettre en évidence les zones d'intérêts et le *graph cut* qui a la mission de donner la segmentation de l'image. Les résultats de segmentation finale sont très satisfaisants ça permet de donner une meilleure segmentation de l'image cérébrale avec un lissage des bordures de l'objet, sans que la valeur du paramètre  $\lambda$  ait une influence sur le résultat final, et donc un gain de temps considérable qui nous évite de chercher la valeur optimale du paramètre  $\lambda$ .

# 5

## CARACTÉRISATION ET CLASSIFICATION DES TUMEURS CÉRÉBRALES

### 1. INTRODUCTION

Le diagnostic des tumeurs cérébrales se base sur un ensemble de données qui sont issues des images médicales et sont connues sous le nom de données radiologiques. Ces caractéristiques regroupent la localisation de la tumeur, sa taille, sa texture, le nombre d'infection et le statut de sa limite.

Dans le domaine médical, la bonne caractérisation permet une bonne classification. Le médecin est le bon classifieur des données médicales. Dans le cas d'une présence d'une tumeur, le médecin peut établir un diagnostic à partir des caractéristiques comme la calcification de la tumeur, la composante kystique, présence de l'œdème, l'hémorragie...etc.

Néanmoins, nous pouvons extraire des attributs à partir des approches mathématiques, ils représentent les caractéristiques artificielles nécessaires pour la classification de ces images cérébrales.

### 2. REDUCTION DE DIMENSIONS

La performance d'un algorithme d'apprentissage dépend fortement des caractéristiques utilisées dans la phase d'apprentissage.

L'augmentation du nombre de caractéristiques (variables) qui modélisent le problème, introduit des difficultés comme l'augmentation de temps de calcul, la complexité. etc...



L'intérêt de la réduction de ces variables devient de plus en plus indispensable en raison de la multiplication des données. La réduction de l'espace de stockage nécessaire, facilite la visualisation et la compréhension des données et diminue le temps d'apprentissage.

Les méthodes de réduction de la dimensionnalité sont généralement classées dans deux catégories :

a- Première catégorie :

Une réduction basée sur une **sélection de caractéristiques**, qui consiste à sélectionner les caractéristiques les plus pertinentes à partir de l'ensemble de données des variables décrivant le phénomène étudié. Parmi ces méthodes nous trouvons Relief, dans cette approche l'utilisateur affecte un poids à chaque descripteur pour voir son intérêt par rapport à un concept cible, par contre cette méthode ne tient pas en compte d'une éventuelle redondance entre les variables.

Nous trouvons aussi la méthode de Wrapper, elles évaluent les sous-ensembles d'attributs en fonction des performances d'un classifieur.

b- Deuxième catégorie :

Une réduction basée sur une transformation de données est connue aussi sous le nom d'**extraction de caractéristiques**. Elle consiste à remplacer l'ensemble initial des données par un nouvel ensemble réduit, construit à partir de l'ensemble initial de caractéristiques. Dans cette catégorie la méthode la plus connue est ACP (Analyse en Composantes Principales), c'est une approche non supervisée, qui recherche les axes qui ont la plus grande variance. Elle permet de bien représenter les données et supprimer les redondances, mais elle ne préserve pas les classes.

Nous trouvons aussi ACI (Analyse en composantes Indépendantes). C'est une méthode non supervisée, elle cherche les axes les plus indépendants, elle cherche aussi les sources, et elle supprime les redondances.

## 5. Classification des images cérébrales

LDA (Analyse Discriminante Linéaire), et MMD (Maximum Marginal Diversity) sont deux méthodes supervisées, elles recherchent les axes les plus discriminants. Ces deux méthodes sont simples et rapides, mais elles gardent les redondances.

Dans notre cas, l'appel à des méthodes de réduction de données n'est pas d'une grande importance. Nous avons extrait 10 attributs, ils représentent les caractéristiques les plus pertinentes qui modélisent les tumeurs cérébrales segmentées.

L'objectif de la classification est d'identifier les classes auxquelles appartiennent des objets à partir de traits descriptifs (attributs, caractéristiques, etc...).

### 3. EXTRACTION DES ATTRIBUTS

Dans le cadre de classification d'images, il est essentiel d'exploiter des attributs qui caractérisent et discriminent au mieux les différentes classes de l'image.

Les régions extraites des images qui sont des lésions cérébrales dans notre cas, elles sont caractérisées par un ensemble d'attributs pour permettre leur identification.

GLCM est la matrice de cooccurrence de niveau de gris de la région segmentée. Il existe 14 paramètres possibles sur les matrices de cooccurrence, comme par exemple l'entropie, la variance, le contraste, l'énergie et l'homogénéité proposé par Haralick [77], [78].

L'histogramme  $h(i)$  d'une image est la fonction qui associe à chaque valeur d'intensité le nombre de pixels dans l'image ayant cette valeur.

$h(i)$  = nombre de pixels de l'image dont le niveau de gris est égal à  $i$ .

Différents attributs peuvent être calculés sur une région. Nous avons extrait 10 attributs :

*Le contraste* : c'est l'opposition de deux choses dont l'une fait ressortir l'autre, c'est l'un des éléments qui caractérise la nature d'une image  $I(i, j)$  et lui donne sa qualité. Le contraste est donné par la formule suivante :

$$\text{contraste} = \frac{\max[I(i,j)] - \min[I(i,j)]}{\max[I(i,j)] + \min[I(i,j)]} \quad (5.1)$$

*L'énergie* : L'intensité de pixel est l'énergie, elle mesure l'uniformité globale de l'image.

$$\text{énergie} = \sum_{i,j} p(i,j)^2 \quad (5.2)$$

$p$  est la fonction de densité de probabilité.

*L'entropie* : c'est une grandeur très importante de la théorie de l'information. Elle est due à Shannon, et représente la quantité moyenne minimale d'information pour représenter une source numérique sans ambiguïté. Dans le cas des images numériques elle s'exprime à l'aide de la formule suivante :

$$\text{entropie} = - \sum_{k=1}^K p_k \log p_k \quad (5.3)$$

$$p_k = \frac{\text{nombre de pixels égaux à } k}{\text{nombre total de pixels de l'image}} \quad (5.4)$$

Où :  $p_k$  représente la probabilité d'apparition du niveau  $k$ .

$K$  est le nombre de niveaux de gris différents dans l'image (généralement 256).

Plus l'entropie est grande, plus l'image est difficile à compresser sans pertes.

*L'homogénéité* : l'homogénéité traduit l'homogénéité locale au sein de la texture [74].

$$\text{homogénéité} = \sum_{i,j} \frac{p(i,j)}{1 + |i - j|} \quad (5.5)$$

## 5. Classification des images cérébrales

Plus nous trouvons le même couple de pixels, plus cet indice est élevé.

*La surface* : c'est le nombre de pixels de la lésion cérébrale.

*Le diamètre* : dans notre cas nous avons calculé le plus grand diamètre de la lésion cérébrale.

*La moyenne* : c'est la moyenne des niveaux de gris des pixels de la même région.

$$\text{moyenne} = \frac{\text{la somme des niveaux de gris de la lésion cérébrale}}{\text{nombre de pixels totale dans la lésion cérébrale}} \quad (5.6)$$

*La variance* :

$$\text{variance}(\sigma) = \frac{1}{N} \sum_{i=0}^{255} h(i) \cdot (i - \mu)^2 \quad (5.7)$$

Avec  $N$  est le nombre de pixel dans une image.

*L'écart type* : mesure la dispersion des valeurs autour de la moyenne ( $\mu$ ).

$$\text{ecart type} = \sqrt{\sigma} \quad (5.8)$$

*La corrélation* : décrit les corrélations entre les lignes et les colonnes de la matrice de cooccurrence de niveau de gris.

$$\text{corrélation} = \sum_{i,j} \frac{(i - \mu_i)(j - \mu_j)p(i,j)}{\sigma_i \sigma_j} \quad (5.9)$$

#### 4. LES DIFFERENTS TYPES D'APPRENTISSAGE

L'apprentissage est une phase du développement d'un classifieur durant laquelle le comportement du classifieur est modifié jusqu'à l'obtention du comportement désiré, il consiste à déterminer les paramètres suivant le problème à résoudre [73].

La plupart des algorithmes d'apprentissage sont des algorithmes d'optimisation : ils cherchent à minimiser par des méthodes d'optimisation non linéaire, une fonction de coût qui constitue une mesure de l'écart entre les réponses réelles du classifieur et ses réponses désirées. Cette optimisation se fait de manière itérative, en modifiant les poids en fonction de la fonction du coût.

Il existe trois grandes familles d'apprentissage :

##### 4.1. APPRENTISSAGE SUPERVISE

L'apprentissage supervisé consiste à modifier les poids tant que la réponse correspondante à chaque entrée n'est pas assez proche de la réponse souhaitée.

Donc nous disposons de la bonne réponse et nous l'utilisons pour mesurer le taux d'erreur dans la réponse du classifieur, puis nous modifions les connexions en fonction de cette erreur.

##### 4.2. APPRENTISSAGE NON SUPERVISE

L'apprentissage non supervisé consiste d'ailleurs comme dans le cas de l'apprentissage supervisé à modifier les paramètres du classifieur. Mais dans ce cas les exemples de la base d'apprentissage sont des données seules, il n'est pas possible de modifier les paramètres du classifieur en fonction d'une erreur sur les réponses souhaitées puisqu'aucune réponse n'est connue a priori.

##### 4.3. APPRENTISSAGE PAR RENFORCEMENT

L'algorithme d'apprentissage par renforcement est de type qualitatif par opposition à l'apprentissage dit supervisé ou non supervisé. Il n'est pas nécessaire de disposer pour les exemples d'apprentissage des sorties désirées, seulement d'une appréciation "globale" du comportement du classifieur pour chacun des exemples traités.

Dans le cas d'un réseau neuronal, un algorithme s'applique à toutes structures de réseaux. La seule condition est de disposer de neurones

## 5. Classification des images cérébrales

de sortie stochastiques (binaires). La réponse du réseau de neurones est ainsi fonction des entrées et, aussi, des neurones de sortie. On introduit donc à ce niveau une part d'aléatoire dans le comportement du système. Si la réponse fournie par le système est considérée comme bonne, l'algorithme tend à favoriser l'apparition de ce comportement en réduisant l'aléatoire. Dans le cas où la réponse du système globale est considérée comme mauvaise, on cherche à éviter l'apparition ultérieure de ce comportement.

Dans les deux cas (apprentissage supervisé et non supervisé), le seul moyen dont on dispose pour améliorer les réponses du système est le réglage des paramètres du classifieur.

### 5. CLASSIFICATION DES IMAGES CEREBRALES

Pour classer les images cérébrales, tumeur ou non tumeurs, 3 classifieurs ont été testés en adoptant 3 modèles distinctes. Le réseau de neurones (réseau multi couches), machine à vecteur support (SVM), et le K plus proche voisins KNN. Nous présentons ci-dessous les trois modèles utilisés:

#### 5.1. RESEAU DE NEURONES MULTI COUCHES

Dans le réseau de neurone multi couches, connu aussi sous le nom Perceptron Multi Couche (PMC), les neurones sont arrangés par couche. Il n'y a pas de connexion entre neurones d'une même couche et les connexions ne se font qu'avec les neurones des couches avales (figure.5.1).

La couche d'entrée est l'ensemble des neurones d'entrée. Elle recevra les données source que l'on veut utiliser pour l'analyse. Dans le cas de l'aide au diagnostic médical, cette couche recevra les symptômes. Sa taille est donc directement déterminée par le nombre de variables d'entrées.

Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelés couches cachées. Les fonctions d'activations sont en général non linéaires sur cette couche mais il n'y a pas de règle à respecter. Le choix de sa taille n'est pas implicite et doit être ajusté.

## 5. Classification des images cérébrales

La couche de sortie est l'ensemble des neurones de sortie ; elle donne le résultat obtenu après compilation par le réseau des données entrée dans la première couche. Dans le cas de l'aide au diagnostic médical, cette couche donne le diagnostic. Sa taille est directement déterminée par le nombre de variables qu'on veut en sortie.




Figure.5.1: Définition des couches d'un réseau multicouche.

Dans le cas général un perceptron multi couche peut posséder plusieurs couches cachées et plusieurs neurones par couche.

Les neurones sont reliés entre eux par des connexions pondérées. Ce sont les poids de ces connexions qui gouvernent le fonctionnement du réseau et programment une application de l'espace des entrées vers l'espace des sorties à l'aide d'une transformation non linéaire.

L'apprentissage du perceptron multi couches est supervisé, et consiste à adapter les poids des neurones de manière à ce que le réseau soit capable de réaliser une transformation donnée.

Le PMC fonctionne en deux phases :

*La phase d'apprentissage* : pendant cette phase le PMC apprend les différents exemples des vecteurs de caractéristiques des images cérébrales que l'on souhaite classifier pour cela nous utilisons :

- La propagation, qui consiste à présenter une configuration d'entrée au réseau, puis à la propager à celle de sortie en passant par les couches cachées.

## 5. Classification des images cérébrales

- La rétro-propagation, consiste après le processus de propagation, à minimiser l'erreur quadratique entre les sorties calculées et celles souhaitées. L'erreur est considérée comme une fonction des poids synaptiques.

*La phase de test* : dite de génération qui consiste à présenter un vecteur de paramètres inconnu en entrée du réseau et à observer la réponse qu'il fournit.

Dans cette phase, nous testons le réseau, et c'est à lui de décider si la région présentée est saine ou présente une lésion cérébrale.

$$\text{taux de reconnaissance} = \frac{\text{nombre des cas correctement reconnus}}{\text{nombre total des cas}}$$

*Affectation des résultats* : on associe à chaque région segmentée une valeur Y qui prend soit 1 pour la présence d'une pathologie ou 0 dans le cas contraire.

Le PMC est un réseau très populaire, à cause sa simplicité, et les bons résultats fournis s'il est bien paramétré. Ça n'empêche pas que ce réseau a des inconvénients, comme modèle boîte noir, danger de sur apprentissage...etc.

### 5.2. MACHINES A VECTEUR SUPPORT (SVM)

Cette technique est une méthode de classification à deux classes qui tente de séparer les exemples positifs des exemples négatifs dans l'ensemble des exemples dont la marge est la plus grande possible, d'où la seconde signification « séparateur à vaste marge ». C'est une approche d'apprentissage supervisé permettant d'apprendre un séparateur afin de réaliser une classification binaire.

L'idée principale repose sur l'hypothèse qu'il existe une séparabilité linéaire entre les classes, si les données sont préalablement projetées dans un espace approprié, plus précisément à grande dimension.

Ils permettent de construire un classifieur à valeurs réelles qui découpent le problème de classification en 2 sous-problèmes : transformation non-linéaire des entrées et choix d'une séparation linéaire optimale.



**SVM linéaire :**

Pour deux classes d'exemples données, le but de SVM est de trouver un classificateur qui va séparer les données et maximiser la distance entre ces deux classes. Avec SVM, ce classificateur est un classificateur linéaire appelé **hyperplan**. Dans le schéma qui suit, on détermine un hyperplan qui sépare les deux ensembles de points.




Figure.5.2. Hyper plan et vecteur support.

Les points les plus proches, qui seuls sont utilisés pour la détermination de l'hyperplan optimal, sont appelés vecteurs de support. Ils sont les plus simples car ils permettent de trouver facilement le classifieur linéaire.

**SVM non linéaire :**

Le cas de SVM non linéairement séparables constituent la plupart des problèmes réels, il n'y a pas de séparation linéaire possible entre les données. La transformation non linéaire est réalisée via une fonction noyau.




Figure.5.3. SVM non linéaire

Le choix pour le classifieur SVM est motivé par les performances élevées qu'il offre, et la remarquable rapidité dans le processus de classification.

### 5.3. K PLUS PROCHE VOISINS (KNN)

C'est une approche très simple et directe, son principe est le suivant : une donnée de classe inconnue est comparée à toutes les données stockées. On choisit pour la nouvelle donnée la classe majoritaire parmi ses K plus proches voisins (Elle peut donc être lourde pour des grandes bases de données) au sens d'une distance choisie.

Afin de trouver les K plus proches d'une donnée à classer, nous pouvons choisir la distance euclidienne.

Dans le cas particulier  $k=1$ , c'est la classe de la forme la plus proche de la forme à classer qui est affectée à cette dernière.

## 6. BASES DE DONNEES

Nous avons choisi 3 bases de données IMAOIS, IMADIS et BrainWeb pour évaluer les résultats obtenus en appliquant notre approche hybride.

IMADIS est une base de données des images médicales d'une façon générale qui contient plus de 40 000 images dont des images cérébrales sains (normales) et avec pathologies (lésions, tumeurs cérébrales), la

## 5. Classification des images cérébrales

chaîne de cas cliniques radiologie d'urgence est le partenaire de IMAIOS.

IMAIOS a été fondée par 2 radiologues montpelliérains en 2008, IMAIOS est une société dédiée à la mise à disposition des professionnels de la santé, des formations, cours et diplômes en ligne de haute qualité scientifique et pédagogique.

Aujourd'hui, IMAIOS est un acteur reconnu par les plus grandes universités médicales dans le monde qui utilisent ses solutions pédagogiques (Yale, Stanford, Harvard, Lyons, Paris Descartes ...)

IMAIOS fournit des images cérébrales (avec ou sans lésions), leur diagnostic mais aussi il existe des cas où le détail va vraiment très loin, nous trouvons par exemple la hauteur et la largeur de la tumeur qui sert à faire une évaluation de notre algorithme.

Chaque cas contient des informations sur le diagnostic, y compris des annotations, l'histoire patiente, les résultats et les images radiologiques.

Avec des e-Cas, apporte la capacité de télécharger et partager les cas interactifs de radiologie et les ateliers médicaux virtuels de formation image.

Nous pouvons regarder des cas dans des spécialités multiples et des modalités et télécharger les dossiers de cas pour seulement ceux qui nous intéressent.

Des cas sont ajoutés régulièrement par des médecins que IMAIOS est en collaboration avec et en outre, par l'intermédiaire des outils en ligne.

BrainWeb est une base de données qui propose des images cérébrales IRM normales et des images cérébrales IRM avec lésions. Elle est très connue dans la littérature.

## 7. EVALUATION DE L'ALGORITHME DE SEGMENTATION

L'interprétation des résultats nécessite tout un traitement des images cérébrales que nous souhaitons classifier, nous avons commencé par la segmentation des images cérébrales en appliquant notre approche hybride, puis nous avons calculé les attributs cités ci-dessus qui

## 5. Classification des images cérébrales

caractérisent ces images. Dans le but d'avoir plus de résultats et les comparer, nous avons construit les trois classifieurs cités précédemment : le RN multi couche, le SVM et le KNN.

En effet, l'évaluation d'un système de traitement d'images médicales n'est pas une chose aisée. Dans le cas de segmentation des lésions cérébrales le problème est encore compliqué car plusieurs paramètres comme le contraste, la finesse et la résolution de l'image peuvent être effectués par les modes d'acquisitions.

Pour tester notre algorithme d'une façon pertinente, nous avons évalué la qualité de segmentation obtenue par rapport aux critères souvent utilisés dans la littérature [80].

*La sensibilité* : elle correspond à la True Positive Fraction

$$\text{sensibilité} = \frac{TP}{TP + FN}$$

*La spécificité* : elle correspond au False Positive Fraction

$$\text{spécificité} = \frac{TN}{TN + FP}$$

Avec

*TP (vrai positif:VP)* : La lésion est correctement détectée par le test.

*FP (faux positif:FP)* : Lorsque le résultat du test est déclaré positif mais il ne l'était pas.

*FN (faux négatif:FN)* : Lorsque le résultat du test est déclaré négatif mais en réalité il est positif.

*TN (vrai négatif:VN)* : La lésion est correctement déclarée comme négative.

Dans le cadre d'aide au diagnostic, la segmentation des lésions cérébrales d'une bonne sensibilité est très importante, par exemple

## 5. Classification des images cérébrales

dans le cas d'un Faux Négatif, le classifieur n'a pas détecté la lésion alors elle existe, ce qui constitue un danger réel pour le patient. Par contre dans le cas d'un Faux Positif, l'erreur du système peut être corrigée a posteriori.

### 7.1. EXPERIMENTATIONS DE CLASSIFICATION

L'algorithme de segmentation hybride proposé, a été appliqué sur une série des images cérébrales, issues de deux bases de données citées précédemment.

Nous avons choisi 85 images cérébrales dont 20 sont des cas sains, et 65 cas contiennent des lésions cérébrales de différents types, issues des deux bases de données IMAIOS et BrainWeb, sur lesquelles nous avons appliqué l'évaluation.

La base de données IMAIOS a été choisie par rapport à la qualité des images proposées et les informations données par le radiologue sur la lésion comme le type de la tumeur, par exemple glioblastome muti forme, astrocytome, la taille de la lésion, etc...

Les attributs cités en section 3, sont utilisés à l'entrée des 3 classifieurs (PMC, SVM et KNN) que nous avons choisi dans ce travail. Nous avons mené 3 expérimentations pour développer et valider nos trois classifieurs.

#### a- PREMIERE EXPERIMENTATION

Nous avons commencé par le PMC pour la première expérimentation. Dans ce cadre, nous avons mené un certain nombre d'essais afin de choisir le meilleur classifieur neuronal.

Dans cette première expérimentation, nous avons fixé le nombre de neurones en entrée à 10 (nombre d'attributs) et un seul neurone de sortie (tumeur : 1 ou non tumeur : 0), et 10 neurones cachés pour le PMC.

b- DEUXIEME EXPERIMENTATION

Pour le classifieur KNN, nous avons utilisé les mêmes caractéristiques citées ci-dessus. La valeur optimale de k a été déterminée en effectuant plusieurs essais sur l'ensemble des images d'apprentissage avec différentes valeurs de k. La valeur optimale trouvée correspond à k=5.

c- TROISIEME EXPERIMENTATION

Concernant le classifieur SVM les mêmes attributs ont été utilisés. Nous avons choisi un classifieur SVM non linéaire, pour sa haute performance.

Le tableau 5.1 montre une comparaison des résultats de classification obtenus en appliquant les trois classifieurs (PMC, SVM, KNN)

Type de classifieur	PMC	SVM	KNN
Sensibilité	92.85%	95.23%	90.12%
Spécificité	89.20%	93.68%	91.45%
Taux de classification	95.41%	96.21%	87.57%

Tableau 5.1. Mesure des performances obtenues par les classifieurs PMC, SVM et KNN.

Le tableau 5.1 compare la sensibilité, la spécificité, le taux de classification, obtenus en appliquant les trois classifieurs, afin d'évaluer notre approche hybride. Néanmoins le SVM a donné les meilleures performances par rapport au PMC et KNN.


Selon les valeurs présentées dans le tableau.5.1, le modèle de classification SVM a donné la meilleur sensibilité de 95.23% des lésions détectés, et avec un bon taux de reconnaissance de 96,21%. La majorité des images sont détectées.

Sur le total des images cérébrales de notre base construite à partir des caractéristiques calculées, notre algorithme a réussi à détecter toutes les tumeurs cérébrales. En revanche elle a détecté 2 faux positifs, qui correspondent à des diamètres et surfaces très petites, dus notamment à la limite de l'approche hybride proposée.

## 5. Classification des images cérébrales

Nous avons réalisé une comparaison entre les mesures des caractéristiques extraites des lésions cérébrales segmentées en appliquant l'approche hybride proposée (en particulier le diamètre et la surface) et les mesures prises par le radiologue (l'expert).

Les images choisies contiennent des tumeurs visibles avec faible contraste, issues toujours de la base de données IMAIOS comme illustré dans la figure 5.4.



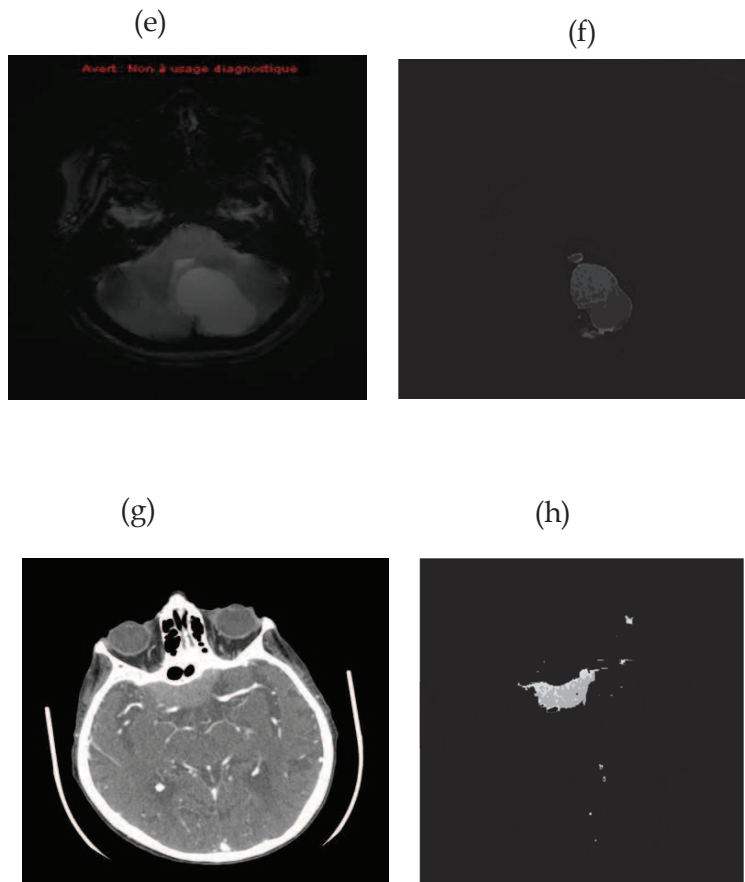


Figure 5.4 : Exemples de segmentation des images cérébrales avec faible contraste issues de la base de données IMAOIS en utilisant notre approche.

La figure.5.4. (a) présente une lésion méningée agressive, avec un faible contraste, on constate dans la figure.5.4. (b) que malgré la présence du fort contraste de couleur blanche dans l'image qui ne fait pas parti de la lésion, notre algorithme a détecté la lésion avec succès.

La volumineuse masse tissulaire extra-axiale mesure 38 mm de grand axe centrée sur le sinus caverneux mesuré par le médecin.

Sur cette image, notre algorithme mesure un diamètre de 145 pixels de la lésion, en convertissant le pixel en millimètre  $145 \text{ pixels} = 38.36 \text{ mm}$ , soit avec une erreur  $e = 0.36 \text{ mm}$  (0.94%). (Tel que  $100 \text{ pixel} = 2.646 \text{ cm}$ ).

La figure.5.4. (c) présente un volumineux méningiome, la figure.5.4. (d) présente l'image segmentée, de taille de la tumeur mesurée par le



## 5. Classification des images cérébrales

médecin est de 7.5 cm, ce qui correspond à 283.46 pixels. Le diamètre présenté dans la figure.5.4 (d) détectée par notre algorithme est de 290 pixels qui correspondent bien au diamètre mesuré par le médecin avec une erreur  $e=6.54$  pixels.

La figure.5.4. (e) présente un Hémangioblastome d'une femme de 41 ans, elle est segmentée par notre approche (voir figure.5.4. (f)). Cette tumeur mesure 30 mm de hauteur selon le médecin. Notre algorithme a détecté un diamètre de la lésion de 110 pixels qui correspond à 29.10 mm soit une erreur  $e=0.89$ mm (2.9%).

La figure 5.4 (g) présente un Méningiome sphénoïdal, la segmentation de cette tumeur est présentée dans la figure 5.4. (h), elle mesure 53 mm, selon l'expert, qui correspond à 200.31 pixels. D'après les caractéristiques extraites, nous avons calculé un diamètre de la lésion de 200 pixels, ce qui donne une erreur de 0.31 pixels (0.15%).

Nous avons pris 71 images pour la base d'apprentissage et 14 images pour la base de test, dont 8 avec tumeur et 6 sans tumeurs avec les faux positifs.

	PMC	SVM	KNN
Taux de classification	92,85%	85.71%	100%

### 5.3. Comparaison du taux de classification.

Le tableau 5.3 présente les résultats obtenus en appliquant les 3 classifieurs, RN multicouche, SVM et KNN :

Le classifieur KNN a un taux de classification de 100% ce qui signifie que le classifieur a reconnu toutes les images avec succès.

Pour le SVM le taux de reconnaissance est de 85.71%, le classifieur a reconnu toutes les images avec tumeurs, mais pour les 6 images sans tumeurs il a reconnu que 4 images, par contre pour les deux cas « faux positifs » il les a détecté comme des images avec tumeurs.




Figure 5.5. (a) image cérébrales saine, (b) vaisseau sanguin de l'image (a). (c) image cérébrale saine, (d) matière de cellule gliale.

En effet ces deux images issues de la base de données BrainWeb, ne contiennent pas de tumeurs, mais il y a une ressemblance en niveaux de gris entre les vaisseaux sanguins ou la matière de cellules gliales et une éventuelle tumeur existante.

Pour le PMC, le taux de classification est de 92.85%, cela est dû à la présence d'une erreur dans les calculs entre la surface donnée par le radiologue et nos calculs de surface. En effet l'image présente une tumeur (volumineux méningiome) avec une surface de 64260 pixels mesuré par l'expert, et de 64789 pixels mesuré par nos calculs soit une différence de 529 pixels).




Figure 5.6. Volumineux méningiome.

Par contre il a reconnu tous les cas sains avec succès, malgré l'existence de deux faux positifs.

Les taux de classification correspondent bien aux erreurs entre les mesures effectués par l'expert, et nos calculs effectués avec notre approche proposée. Les taux d'erreurs sont très réduits.

Il existe plusieurs travaux qui traitaient le problème de classification et la détection des tumeurs mais il est très difficile de comparer nos résultats avec ces travaux pour une simple raison, nous n'utilisons pas la même base de données.

Néanmoins, nous avons comparé les résultats obtenus par l'approche proposée avec deux autres algorithmes, le premier est l'algorithme standard de graph cuts et le deuxième est l'algorithme de Bricq [81].

	Sensibilité	Spécificité	Taux de classification
Boykov et Jolly	85,91%	89,36%	89,28%
Bricq et al	90.64%	99.16%	-----
Notre approche	93.23%	96.68%	96.21%

Tab.5.4. comparaison de mesures de performances de notre algorithme avec l'algorithme de Boykov-Jolly et approche de Bricq.

Le tableau 5.4 compare les résultats obtenus de la sensibilité, la spécificité et le taux de classification obtenue par notre approche hybride, la méthode standard de Graph cuts de Boykov-Jolly, et l'approche de Bricq.

## 5. Classification des images cérébrales

Dans les travaux de Bricq, ils ont utilisé la base de données IBSR avec un classifieur bayésien pour la détection des tumeurs cérébrales, leur modèle de classification présente un taux de spécificité proche du 100%.

Pour notre approche et l'approche de Boykov-Jolly, nous avons utilisé les mêmes images de la même base de données IMAIOS, nous avons appliqué les mêmes caractéristiques pour les trois classifieurs (PMC, SVM et KNN), le SVM a donné les meilleurs résultats en comparant avec la méthode de Boykov-Jolly avec un taux de classification respectif de 96.21% et 89,28%.

## 8. CONCLUSION

La segmentation des images cérébrales contenant des lésions avec faible contraste constitue un défi pour l'utilisateur, dans plusieurs cas le médecin injecte un produit de contraste afin de rendre la tumeur plus visible.

Cette partie de segmentation est primordiale car elle constitue la base de travail de notre thèse. Nous avons appliqué notre approche hybride proposée où nous avons combiné l'algorithme Graph cuts et l'algorithme ISODATA, qui améliore la qualité de segmentation même dans le cas de faible contraste, nos résultats sont nettement meilleurs en comparaison avec d'autres travaux de littérature.

Les images cérébrales avec ou sans tumeurs sont issues des trois bases de données : IMADIS, IMAIOS et BrainWeb. Dans la base de données IMAIOS ; les médecins offrent le diagnostic et les détails sur la tumeur comme le diamètre et la surface qui nous a permis de comparer et de valider notre approche.

Les calculs du diamètre et de la surface que nous avons effectués pour extraire les caractéristiques, correspondent bien aux calculs et aux informations données par les médecins dans la base de données IMAIOS, avec un taux d'erreur très réduit.

Pour valider notre algorithme, nous avons opté pour trois classifieurs, le premier classifieur est basé sur les réseaux de neurones, nous avons choisi le perceptron multi couches, le deuxième est le SVM et le troisième KNN que nous avons construit à partir des attributs et des

## *5. Classification des images cérébrales*

caractéristiques extraites des images cérébrales segmentées en appliquant notre approche hybride. Les meilleurs résultats de classification sont ceux du classifieur SVM connu par ces performances élevées avec un taux de classification de 96.21%.

Nous avons validé les calculs du diamètre et la surface des caractéristiques, en comparant nos calculs avec les mesures qui sont offert par les médecins dans la base de données IMAIOS.

## CONCLUSION GENERALE ET PERSPECTIVES

### I. CONCLUSION

Comprendre le corps humain et améliorer l'état de santé des patients sont deux motivations qui ont conduit au développement d'une grande variété du système d'imagerie médicale. Les lésions cérébrales font l'objet de plusieurs études et travaux dans la littérature

Les travaux de cette thèse concernent en particulier la segmentation et la classification des lésions cérébrales.

Pour la partie segmentation, nous avons présenté une approche hybride basée sur la combinaison de deux méthodes existantes dans la littérature. La première est le seuillage itératif connu sous le nom ISODATA, cet algorithme sert comme un prétraitement de l'image qu'on souhaite segmenter. En effet ISODATA met en évidence la lésion cérébrale et la rend plus visible.

Ensuite nous avons appliqué l'algorithme standard de Graph cuts, cette combinaison entre les deux approches nous a permis d'améliorer le Graph cuts basique et donc les résultats sont nettement meilleurs et prometteurs en comparant avec l'utilisation du standard Graph cuts uniquement.

En effet, l'utilisateur de standard Graph cuts consomme beaucoup de temps en cherchant la valeur optimale de  $\lambda$  qui permet la segmentation optimale de la région ciblée.

Alors que pour notre version améliorée, la segmentation de l'image ne dépend absolument pas du paramètre  $\lambda$ .

La discussion des résultats obtenus a montré clairement que notre approche de segmentation proposée a obtenu des résultats encourageants même dans le cas des images faiblement contrasté.

Aussi le temps de calcul est largement diminué par rapport aux approches standards. Elle fonctionne très bien sur les images qui présentent un faible contraste de l'objet (la lésion) et un fort contraste sur les autres parties de l'image.

Cependant et bien que notre méthode fonctionne sur la majorité des images cérébrales, nous avons constaté que lorsque il y a une forte ressemblance en niveaux de gris entre l'objet (la lésion cérébrale) et d'autres parties de l'image qui ne représente pas l'objet, notre algorithme le détecte comme lésion cérébrale parce que ce dernier est attribué par le même étiquetage.

Dans la partie classification, nous avons calculé un ensemble d'attributs et caractéristiques dans le but de construire trois classifieur (PMC, KNN, SVM) pour faire la reconnaissance.

Nous avons réalisé plusieurs expérimentations de classifications, les résultats obtenus sont très prometteurs et ils ont montré l'intérêt de la méthode de segmentation adoptée.

## II. PERSPECTIVES

Comme suite à ce travail de thèse, nous avons proposé plusieurs propositions :

- 1- Améliorer l'algorithme de segmentation proposée pour qu'elle puisse détecter l'objet qui nous intéresse uniquement en cas de forte ressemblance entre l'objet et autres parties de l'image.
- 2- La segmentation par l'approche hybride présentée dans cette thèse peut être appliquée sur d'autres types d'imagerie médicale comme par exemple la mammographie, l'abdomen...etc. En

ajustant les paramètres de cette technique pour s'adapter aux autres images ciblées.

- 3- Trouver les mécanismes d'application de notre approche de segmentation sur des images couleur et chercher à détecter uniquement l'objet intéressant en cas de ressemblance de couleur.
- 4- Proposer des nouveaux attributs pour la classification des images médicales.
- 5- Améliorer l'algorithme et l'appliquer sur des images trois dimensions.



## REFERENCE

- [1] :[www.unilim.fr/campus.../Tumeurs\\_intracr\\_oniennes.pdf](http://www.unilim.fr/campus.../Tumeurs_intracr_oniennes.pdf)
- [2] :<http://www.unilim.fr/campus-neurochirurgie/IMG/pdf/>
- [3] :<http://dteirm.e-monsite.com/rubrique,tumeurs-cerebrales,1062812.html>
- [4] :<http://www.vulgaris-medical.com/encyclopedie/cerveau-980.html>
- [5] :[www.info-radiologie.ch/glioblastome](http://www.info-radiologie.ch/glioblastome).
- [6] :[www.info-radiologie.ch/oligodendrogliome](http://www.info-radiologie.ch/oligodendrogliome).
- [7] :[www.igr.fr/index\\_m=pediatrie&p\\_id=2792](http://www.igr.fr/index_m=pediatrie&p_id=2792)
- [8] :<http://www.santetropicale.com/santemag/maroc/lcpcc.htm>
- [9] :[www.info-radiologie.ch/scanner-meningiome.php](http://www.info-radiologie.ch/scanner-meningiome.php)
- [10] :[www.info-radiologie.ch/schwannome-acoustique](http://www.info-radiologie.ch/schwannome-acoustique)
- [11] : [campus.neurochirurgie.fr/spip.php?article358](http://campus.neurochirurgie.fr/spip.php?article358)
- [12] : [http://www.info-radiologie.ch/hemangioblastome\\_cerebelleux.php](http://www.info-radiologie.ch/hemangioblastome_cerebelleux.php)
- [13] :[www.info-radiologie.ch/adenome-hypophyse-irm.php](http://www.info-radiologie.ch/adenome-hypophyse-irm.php)
- [15]N. Otsu, "A threshold Selection Method from Grey-Level Histograms", IEEE Trans. System, Man, and Cybernetics, vol. 9, 1, pp.377-393, 1979.
- [16] S.S. REDDI, S.F. RUDIN, and H.R. KESHAVAN, An optimal multiple threshold scheme for image segmentation, T-SMC, SCM-14;661-665, 1984.
- [17] M. Cheriet, J. N. Said, C.Y. Suen. «A recursive thresholding technique for image segmentation ». IEEE Transactions on Image Processing, vol. 7, n.6, June 1998.

- [18] F. R. D. Velasco, "Thresholding using the isodata clustering algorithm," IEEE Trans. Syst. Man Cybern. SMC-10, PP 771-774, 1980.
- [19] K.Chedi, D.Coquin, Binarisation of various images bu detecting local threshold with a validation test. IEEE Pacific RIM Conference on Communications Computers ans Signal Processing, pp. 611-614. 1991
- [20] A. Nakib. Conception de metaheuristique d'optimisation pour la segmentation d'iage. Application à des images biomédicale. Thèse doctorat 2007.
- [21] N. Xu, R. Bansal et N. Ahuja : Object segmentation using graph cuts based active contours. Computer Vision and Pattern Recognition, 2:46, 2003.
- [22] J. Kittler and J. Illingworth, "Minimum error thresholding," Pattern Recognition.Vol19, PP 41-47. 1986.
- [23] RaminZabih and Vladimir Kolmogorov. Spatially coherent clustering using graph cuts. In CVPR (2), pages 437-444, 2004.
- [24] C. K. Chow and T. Kaneko Boundery Detection of Radiographic Images by a Threshold Method.In proceedings, p. 130-134, IFIP Congress 1971.
- [25] M. X. Fernando and D. M. Monro Variable Thresholding applied to Angiography, in Proceeding, 6th International Conference on Pattern Recognition, 1982.
- [26] A. Rosenfeld and P. De la Torre, "Histogram concavity analysis as an aid in threshold selection," IEEE Trans. Syst. Man Cybern.SMC-13, PP 231-235. 1983.
- [27] L. KAABI Segmentation d'image et classification de formes: Théorie et Application Thèse de l'Université Paul Sabatier, St-Etienne, 1988.
- [28] T. Pun, "A new method for gray-level picture threshold using the entropy of the histogram," Signal Process.Vol2 (3), PP. 223-237. 1980.
- [29] Y. Boykov , G. Funka-Lea "Graph cuts and efficient n-d images segmentation". Interna-tional Journal of Computer Vision, Vol 70(2), PP 109-131. 2006.

- [30] G. Johannsen and J. Bille, "A threshold selection method using information measures," ICPR'82: Proc. 6th Intl. Conf. Pattern. Recognition, pp. 140-14. 1982.
- [31] L.Chang, W.H.Hsu, "Foreground segmentation for static video via multi-core and multi-modal graph cut", International Conference on ICME, PP 1362-1365. 2009.
- [32] V.Lempitsky, P.Kohly, C.Rother, T.Shrap. "Image segmentation with a bounding box prior".IEEE Conference on Computer Vision. PP 277-284. 2010.
- [33] J. N. Kapur, P. K. Sahoo, and A. K. C. Wong, "A new method for gray-level picture thresholding using the entropy of the histogram," Graph. Models Image Process.Vol29, PP. 273-285. 1985.
- [34] Y. Peng, R.Liu, " Object segmentation based on watershed and graph cut". International Congress on CISP, PP 1431-1435. 2010.
- [35] P. Sahoo, C. Wilkins, and J. Yeager, "Threshold selection using Renyi's entropy," Pattern Recognition Vol30, PP. 71-84 1997.
- [36] k. Sahoo, P.K.Prasanna, G. Orora, " Imagethresholding using two dimensionalTsallis-Havrda-Charvat entropy,". Pattern Recongnition Letters Vol 27. PP. 520-528. 2006.
- [37] A.Nakib, S.Roman, H.Oulhadj and P.Siarry, "Fast MRI segmentation based on two dimentional survival exponential entropy and particle swarm optimization ,". In Porc.Of the 29th annual Interbational conference on the IEEE.EMBS. Lyon, PP 5563-5565, 2007.
- [38] L. Ford et D. Fulkerson , "Flows in Network". Princeton Unviersity Press, 1962.
- [39] E. Dinic "Algorithm for solution of a problem of maxium flow in networks with power estimation". Soviet Mathematics Doklady, Vo1 11, PP 1277-1280, 1970.
- [40] D. Greig, B. Porteous, and A. Seheult. "Exact maximum a posteriori estimation for binary images".Journal of the Royal Statistical Society, Series B, 51(2), PP271-279, 1989.
- [41] S. Roy et I. Cox "A maximum-flow formulation of the camera stereo correspondence problem". International Conference on Computer Vision, PP 492-499, 1998.

- [42] Y. Boykov, O. Veksler and R. Zabih "Fast Approximate Energy Minimization via Graph Cuts" IEEE transactions on pattern analysis and machine intelligence, vol 23, No 11, pp 1222-1239. November 2001.
- [43] V. Kolmogorov et R. Zabih "What energy functions can be minimized via graph cuts ? " IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol 26(2): PP 147-159, 2004.
- [44] Z. Wu, R. Leahy, " An optimal graph theoretic approach to data clustering: theory and its application to image segmentation". IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol 15(11), PP1101-1113. 1993.
- [45] J. Shi, J. Malik, " Normalized cuts and image segmentation ". IEEE Computer Society Conference on Computer Vision and Pattern Recognition. PP 731-737. 1997.
- [46] J. Shi, J. Malik " Normalized cuts and image segmentation ". IEEE Transactions on Pattern Analysis and Machine intelligence, Vol 22(8), PP 888-905. 2000.
- [47] A. Blake, C. Rother, M. Brown, P. Pérez, P. Torr "Interactive image segmentation using an adaptive GMMRF model". European Conference on Computer Vision, PP 428-441, 2004
- [48] Y. Boykov, M.P. Jolly " Interactive graph cuts for optimal boundary & region segmentation of objects in N-D images". International Conference on Computer Vision, Vol 1, PP 105-112, 2001.
- [49] Y. Boykov. M.p. Jolly "Interactive Organ Segmentation Using Graph Cuts", Medical image Computing and Computer Assisted Intervention 5MICCAI), LNS1935, PP 276-286, Pittsburgh. 2000.
- [50] Y. Boykov, M.P. Jolly "Demonstration of segmentation with interactive graph cuts". International Conference on Computer Vision, Vol 2, PP 741-741, 2001.
- [51] V. Kolmogorov , R. Zabih " What energy functions can be minimized via graph cuts ? " . IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol 26(2), PP 147-159. 2004.

- [52] C. Rother, V. Kolmogorov , A. Blake “Interactive foreground extraction using iterated graph cuts”. SpecialInterest Group on Graphics and Interactive Techniques, PP 309-314, 2004.
- [53] D. Maquin, “Elément de théorie des graphes”, Institut national polytechnique de Lorraine, Ecole nationale supérieure d’électricité et de mécanique. Mai 2003.
- [54] F.Yi, I. Moon, “ Image segmentation: A survey of graph cut methods”, International conference and informatics (ICSAI), pp 1936-1941, 2012.
- [55] N.Abdmouleh, V.Chen, S.Ruan, “segmentation interactive d’objet d’intérêt d’images par la coupe des graphes”, Inria, mai 2011.
- [56] Y.Boykov , V. Kolmogorov, “ Applications of parametric maxflow in computer vision”, IEEE 11<sup>th</sup> International Conference on computer vision, pp 1-8, 2007.
- [57] B.Peng, O, Veksler. Parameter selection for graph cut based image segmentation, British machine vision Conference, BMVC, 2008.
- [58] s. Touhami. Classification non supervisée de pixels d’images couleur par analyse d’histogramme tridimensionnel . DEA automatique et informatique appliquée université d’Anger. Septembre 2005.
- [59] O. Abdelli « Segmentation d’images par seuillage d’histogramme bidimensionnel » Mémoire de magister en automatique M. MaamriTiziouzou. Juillet 2011.
- [60] G.Ball, D.Hall, ISODATA, A novel method of data analysis and pattern classification. Technical report. Stanford Research Institute. April 1965
- [61] YuriBoykov and Vladimir Kolmogorov.An Experimental Comparison of Min-Cut/Max-Flow Algorithms for Energy Minimization in vision. In 3rd. Intl.Workshop on Energy Minimization Methods in Computer Vision and Pattern Recognition (EMMCVPR).Springer-Verlag,Vol 2134 pp 359-374 September 2001.

- [62] V. Kolmogorov, Y. Boykov, C. Rother. Applications of Parametric Maxflow in Computer Vision. International Conference on Computer Vision, pp. 1-8 (2007)
- [63] M. FRADET, Contribution à la segmentation de séquences d'images au sens du mouvement dans un contexte semi-automatique. Thèse Doctorat université de RENNES 1. Jan 2010.
- [64] Bo Peng, Lei Zhang, David Zhang, Jian Yang, Image segmentation by iterated region merging with localized graph cuts pattern Recognition, doi:10.1016/j.patcog.2011
- [65] B. Menze, A. Jakab, S. Bauer et al. The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS). IEEE Transactions on Medical Imaging, Institute of Electrical and Electronics Engineers (IEEE), pp.33, 2014.
- [66] A. Capelle Segmentation d'images IRM multi-échos tridimensionnelles pour la détection des tumeurs cérébrales par la théorie de l'évidence Docteur de l'université de Poitiers. 2002.
- [67] S. Ho, E. Bullitt, and G. Gerig, "Level-set evolution with region competition: automatic 3D segmentation of brain tumors," in Proc ICPR, pp. 532-535, 2002.
- [68] D. Zikic, B. Glocker, E. Konukoglu, A. Criminisi, C. Demiralp, J. Shotton, O. M. Thomas, T. Das, R. Jena, and P. S. J., "Decision forests for tissue-specific segmentation of high-grade gliomas in multichannel MR," in Proc MICCAI, 2012.
- [69] E. Geremia, B. H. Menze, O. Clatz, E. Konukoglu, A. Criminisi, and N. Ayache, "Spatial decision forests for MS lesion segmentation in multi-channel MR images." in Proc MICCAI, ser. LNCS 7511, 2010.
- [70] K. Van Leemput, F. Maes, D. Vandermeulen, and P. Suetens, "Automated model-based bias field correction of MR images of the brain." IEEE T Med Imaging, vol. 18, pp. 885-896, 1999.
- [71] J. Ashburner and K. J. Friston, "Unified segmentation," Neuroimage, vol. 26, no. 3, pp. 839-851, 2005.

- [72] Y. OUSSAR Réseaux d'ondelettes et réseaux de neurones pour la modélisation statique et dynamique de processus. Thèse de doctorat de l'université Pierre et Marie Curie Paris. Juillet 1998.
- [73] N. MEZHOUD. Une approche hybride pour la segmentation d'images. Application aux images médicales. Thèse de doctorat de l'université de Mentouri Constantine. Janvier 2012.
- [74] A. POREBSKI. Sélection d'attributs de texture couleur pour la classification d'images. Application à l'identification de défauts sur les décors verriers imprimés par sérigraphie. Thèse de doctorat de l'université de Lille 1. Novembre 2009.
- [75] R. KACHOURI. Classification multi modèles des images dans les bases hétérogènes. Thèse de doctorat de l'université d'Evry val d'Essonne. Juin 2010.
- [76] D. SEMAI, C.FRELICOT, P.COURTELLEMONT. Une approche de type filtrage pour la sélection de variable. Application à la reconnaissance automatique de poissons. Cretsi . septembre 2005.
- [77] HARALIKA, M. ROBERT, K. SHANMUGAM. Textural features for images classification.IEEE .Trans on Sys, Man and Cybernatics, vol. SMC 3, n. 6, pp 6010-621. November 1973.
- [78] HARALIKA, M. ROBERT. Statistical and structural approaches to texture.Proceedings of IEEE. Vol 67, n.5. May 1979.
- [79] S. BRICQ. Segmentation d'images IRM anatomique par inférence bayésienne multi modales et détection de lésions. Thèse de doctorat de l'université Louis Pasteur. Strasbourg. 2008.
- [80] N. RICHARD. M.DOJAT.C.CARBAY. Automated segmentation of human brain MR images a multi agent approach. Artificiel intelligence in Medicine.Vol 30.Pp 153-175. 2004.
- [81] S. BRICQ. Segmentation d'images IRM anatomiques par inférence bayésienne et détection de lésions. Thèse de doctorat. Université Louis Pasteur. 2008.
- [82] T.BAAKEK. M.A. CHIKH. Interactive image segmentation based on graph cuts and automatic multilevel thresholding for brain images. 2014

## *Références*





# Interactive Image Segmentation Based on Graph Cuts and Automatic Multilevel Thresholding for Brain Images

Baakek Touria\* and Chikh Mohamed Amine

*Faculty of Sciences Engineering, Biomedical Engineering Laboratory (GBM),  
Department of Electrical Engineering and Electronics, Tlemcen University, B.P. 119 Tlemcen, 13000, Algeria*

This paper describes an iterated automatic histogram multilevel thresholding combining with graph cuts algorithm for image segmentation. The contribution of this work resides in the good performances of segmentation obtained. Our objective is to increase the efficiency tumor segmentation shown in brain images in order to bring visual information for diagnosis help. Image thresholding is very useful tool to separate objects and backgrounds. Standard graph cuts consist to found an optimal solution to a wide class of energy functions. The proposed algorithm start with initial segmentation using multilevel thresholding, the segmented regions, pixels are considered as the nodes in the graph cuts. Experimentally our results are much better than segmentation obtained by graph cuts algorithm, this method can be employed to other types of images as well without the influence of  $\lambda$  well without the influence of  $\lambda$ .

**Keywords:** Segmentation Brain Images, Graph Cuts, Automatic Histogram Multilevel Thresholding.

## 1. INTRODUCTION

Segmentation subdivides an image into its regions of components or objects and it is an important tool in medical image processing. The segmentation of anatomic structure in the brain plays a crucial role in Nero imaging analysis. Different approaches to brain image segmentation which are most frequently are used for comparison;<sup>16</sup> such as edge based technique for brain image segmentation edge, split and merge technique for brain image segmentation, fuzzy thresholding method for brain image segmentation.

Interactive image segmentation became an important field in vision by computer. It used more and more frequently in this type of approach to circumvent the problem of automatic segmentation does not always give satisfactory results.

The extraction of object of interest in an image is useful especially important for the analysis of medical images. Several approaches were proposed these last years combining with graph cuts method: the segmentation by morphological gradient,<sup>10</sup> the active contours based on the deformation of a surface formed initially,<sup>17</sup> iterate merging region with localized graph cuts,<sup>6</sup> geodesic active contours and level set method.<sup>3</sup> Another preferable interactive segmentation method based on combinatorial optimisation framework for image segmentation via  $S/T$  graph cuts.<sup>3</sup>

\*Author to whom correspondence should be addressed.

In Ref. [1] Greig et al. were the first to discover that powerful graph cut algorithms from combinatorial optimization can be useful for computer vision problems. In particular, they showed that graph cuts can be used for restoration of binary images. After the general concept of using binary graph cut algorithms for object segmentation was first proposed and tested in Boykov and Jolly<sup>20</sup> were proposed a very effective method for interactive segmentation based on graph cuts. An energy function based on both boundary and region information is then minimized subject to these user-imposed constraints. The result with a relatively small amount of user input, the algorithm segments a variety of objects from both medical images. In Ref. [19] minimum cut/maximum flow algorithms on graphs introduced by Boykov-Kolmogorov et al. emerged as an increasingly useful tool for exact or approximate energy minimization in low-level vision. The combinatorial optimization literature provides many max-flow/min-cut algorithms with different polynomial time complexity. In many case the Boykov/Kolmogorov algorithm worked several times faster than any other methods, making near real-time performance possible.

In Ref. [2] Karger et al. proposed a method approximating the minimum cut on a graph with several terminal nodes. This approach is attractive, but the quality of the energy minimum is found directly correlated to the density of the graph. In other words, the graph is denser, and the result is good. The density of the neighborhood graph depends  $N$  considered. Many algorithms,

often with their cohort of heuristics have been developed to find a maximum flow in a graph. They are divided into two classes: algorithms “Ford-Fulkerson” and algorithms “Push relabel.”<sup>4</sup>

Histogram-based image segmentation is one of the simplest segmentation techniques. It uses the histogram which is the graphical representation of the tonal distribution in a digital image to select the grey levels for grouping pixels into regions. Multilevel thresholding is a process that segments a gray-level image into several distinct regions. This process is often designed using the gray-level histogram of the image.

In Ref. [28] Otsu’s method has been widely applied in image processing, it used an interclass variance criterion for bi-level thresholding, Otsu’s method choose optimal thresholds by maximizing the between variance; and minimization of within-class variance. This method gives satisfactory results when the number of pixels in each class is close to each other; the function formulated by Otsu’s is one of the most referred thresholding methods. To generalize the method to multilevel thresholding method, this method which called the “interactive threshold selection method” proposed by Reddi et al.<sup>29</sup> is fast but its performance depends on the initial value of thresholds, the getting a good performance, it is suggested to evenly distribute the initial thresholds in the histogram space.

The approach proposed in Ref. [25] makes thresholding technique which was based on constructing colour and hue histograms. Kurugollu et al.<sup>26</sup> proposed a novel concept for multi band image segmentation has been proposed based on segmentation of subsets of bands using multilevel thresholding followed by fusion of the resulting segmentation channel. In Ref. [27] the multivariate automates thresholding criterion is one of the robust multilevel thresholding techniques in image segmentation area.

In this paper we propose a method for image segmentation based on graph cuts algorithm and automatic histogram multilevel thresholding (classification) occurs in two steps; first make a classification of the image to be segmented by calculating the different modes of the histogram, representing all the object class in the image. Then we apply the graph cuts algorithm adopting max flow approach. This study makes possible to obtain better segmentation then using only graph cuts standard.

We present in Section 1 a review of standard graph cuts algorithm; a brief review of automatic histogram multilevel thresholding algorithm in Section 2, and we propose in Section 3 our method of combining the two methods together, followed by a discussion of the results obtained in Section 4, the conclusion is made in Section 5.

## 2. METHODS

In this section, we present image segmentation by graph cuts algorithm and segmentation by automatic histogram multi thresholding.

### 2.1. Image Segmentation by Graph Cuts

An undirected graph<sup>6</sup>  $G = (V, E)$ ,  $V = \{v_1, \dots, v_n\}$  is a set of nodes (vertices) corresponding to the image elements, which might represent pixels or regions in the Euclidian space.  $E$  is a set of edges connecting certain pairs of neighbouring vertices.

Each edge  $(v_i, v_j) \in E$  has a corresponding weight  $w(v_i, v_j)$  which measures a certain quantity based on the property between the two connected by that edge.

This method is based on neighbourhood graphs, so each pixel of the image becomes a node in the graph and edges from this node join nodes representing neighbouring pixels.

A cut in a graph is related to a set of edges by the graph  $G$  will be partitioned into two set  $A$  and  $B$ , so the result is an image segmentation can be defined by

$$cut(A, B) = \sum_{u \in A, v \in B} w(u, v) \quad (1)$$

$u$  and  $v$  refer to vertices in the two different components.

Graph cut image segmentation can be formulated as an energy minimization problem.<sup>20</sup> Consider  $p$  a set of pixels and  $L$  a set of labels, the goal is to find a labelling  $f: P \rightarrow L$  that minimize the energy

$$E(f) = R(f) + \lambda \cdot B(f) \quad (2)$$

Where

$$R(f) = \sum_{p \in P} R_p(f_p) \quad (3)$$

and

$$B(f) = \sum_{\{p, q \in N\}} B_{\{p, q\}} \delta(f_p, f_q) \quad (4)$$

And

$$\delta(f_p, f_q) = \begin{cases} 1 & \text{if } f_p \neq f_q \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

The coefficient  $R_p$  and  $B_{\{p, q\}}$  are region and boundary terms that specifies the penalties for assigning pixel  $p$  to “object” and “background,” and a penalty for a discontinuity between  $p$  and  $q$  respectively.

The parameter  $\lambda$  is used to control relative importance of the region term and the boundary term; if  $\lambda$  ( $\lambda \geq 0$ ) is very small, only the region term matters, so the label of each site is independent from the other sites; if  $\lambda$  is very large, all the seeds will have the same label.<sup>6</sup> Minimization of the energy function can be done using the max-flow algorithm as described in Ref. [20].

### 2.2. Image Segmentation by Automatic Histogram Multilevel Thresholding

Histogram threshold approach is based on partitioning an image into regions that are similar according to predefined criteria. Histogram of an image is a function giving, the number of pixels to a particular gray level based on the gray level. The histogram contains no information about the location of pixels or the relative proximity of two pixels, but the information it contains may relate to the apparent brightness and contrast of an image.

Suppose that the gray-level histogram corresponds to an image,  $f(x, y)$ , composed of dark objects in a light background, in such a way that object and background pixels have gray levels grouped into two dominant modes. One obvious way to extract the objects from the background is to select a threshold ‘ $T$ ’ that separates these modes. Then any point  $(x, y)$  for which  $f(x, y) > T$  is called an object point, otherwise, the point is called a background point.

In multilevel thresholding the histogram has to be partitioned by multiple thresholds, and classifies a point  $(x, y)$  as belonging: to one object class if  $T1 < f(x, y) \leq T2$   
to the other object class if  $f(x, y) > T2$   
and to the background if  $f(x, y) \leq T1$

First we select an initial estimate for  $T$ , then we Segment the image using  $T$ . This will produce two groups of pixels.  $G1$  consisting of all pixels with gray level values  $> T$  and  $G2$  consisting of pixels with values  $\leq T$ , and we Compute the average gray level values  $mean1$  and  $mean2$  for the pixels in regions  $G1$  and  $G2$ , finally we Compute a new threshold value  $T = (1/2)(mean1 + mean2)$ .

In the global method, the principle idea is to find the different modes of the histogram, representing all class objects in the image. We generally seek thresholds from a histogram analysis. This algorithm<sup>12</sup> determines the global thresholds by requiring, as a priori, only the initial choice of mean values associated with each of the  $n$  classes.

$p(j)$  is the probability density of the attribute  $j$  of the original image; definitions by [min max] the smallest interval containing non-zero values of  $p(j)$ .

In a first step, Figure 1 shows an initial estimate of the mean values of the attribute  $j$  associated with each of  $n$  classes is given by the average gray level value  $m_i, i = 1, \dots, n$  for pixels in regions. This estimation can be done by dividing the  $j$  axis from min to max the  $n$  equidistant classes on the axis  $j$ , and calculating the arithmetic mean of each class as if the probability density of the attribute was consistent between min and max.

Thresholds  $T_i$  are evaluated using the following equation

$$T_i = [(m_i + m_{i+1})/2], \quad i = 1, \dots, n - 1 \quad (6)$$

After calculating the thresholds, must have assigned all the class  $i, (i = 1, \dots, n)$  item of the picture that the attribute is in




Fig. 1. (a) Original brain image contain tumor. (b) The histogram of (a).




Fig. 2. Initial estimate of the mean of each class.

the range  $A_i = [T_{i-1}, \dots, T_i]$  pour  $i = 1, \dots, n$ , avec  $T_0 = \min - 1$  et  $T_n = \max$ .

Then, the update is done for the average  $m_i$  case  $n$ , according to following equation

$$m_i = \frac{[\sum_{j \in A_i} j p(j)]}{[\sum_{j \in A_i} p(j)]} \quad (7)$$

### 3. METHODS USED

To guide and improve the segmentation process, we propose to combine the method of graph cuts and segmentation by automatic histogram thresholding. The first applications standard graph cuts show that the minimum energy obtained is generally better than with conventional techniques. In this paper we adopt a simple but effective strategy to solve the disadvantages of image segmentation by graph cuts technique. Image segmentation approaches based on graph cuts, in general, have high computation complexity and poor real-time performance.<sup>22</sup> In this framework in order to improve the quality of image segmentation, we have recourse to the Boykov-Kolmogorov's algorithm.<sup>19</sup>

Thresholding offers an efficient way, in terms of both the processing time and the implementation simplicity, to perform image segmentations. However, automatic determination of the optimum threshold value is often a difficult task in digital image processing.

#### Algorithm

Input original image, number of class.

Output segmentation result (segmented image).

1. Initial selection of the average values associated with each of the  $n$  classes.

2. Calculate the probability density function  $p(j)$  of  $j$  in the original image.




Fig. 3. (a) Original brain image contain tumor. (b) The segmentation result by graph cuts algorithm (max flow).

3.  $[\min \max]$  is the smallest interval containing non-zero values of  $p(j)$ .

4. Calculate the threshold  $T$  corresponding to the means values  $m_i$  of  $j$  associated with each of the  $n$  class.  $T_i = [(m_i + m_{i+1})/2]$ ,  $i = 1, \dots, n-1$ .

5. Build object and background data models based on labelled regions.

6. Use graph cuts (max flow) algorithm.

7. Go back to step 4 until  $p(j)$  moves to the closest gravity center.

#### 4. RESULTS AND DISCUSSION

The proposed method has been applied to brain images; the goal is to segment brain tumors existing. We used the histogram multilevel thresholding as initial image segmentation, then we applied the graph cut algorithm (max flow), so each pixel in the segmented region by multilevel thresholding will be a node in the graph. Thresholding aims to segment an image into several classes using only histogram. The general idea of these methods is to isolate peaks of the histogram. In most cases and for reasons related to technical difficulties and areas applications, the thresholding operation is treated as a comparison threshold defining the boundary between the class “background” and the class “object.” The extension in case of multiple thresholds is often referred to multi thresholding or classification. We used automatic thresholding for initial segmentation, so the segmented regions pixels by thresholding are consider as the nodes in the graph cuts. We used the max flow algorithm described in Ref. [20] to implement our proposed method. The segmentation method has been applied to several brain images from different patients. We also

applied graph cuts (max flow) algorithm to the brain images to estimate quantitatively the segmentation results obtained.

Figure 4 shows the segmentation result of the proposed method. The difficulty of this task lies in the choice of the optimal number of classes, when the choice is made, the graph cuts algorithm (Max flow) is applied to build the graph using the algorithm of Boykov-Kolmogorov's.<sup>19</sup>

The second difficulty lies in the choice of  $\lambda$  in graph cuts algorithm to obtain better image segmentation.  $\lambda$  is used to weight  $R_p(f_p)$  and  $B_{(p,Q)}\delta(f_p, f_Q)$ , Boykov-Kolmogorov<sup>19</sup> and in Ref. [6] they have study the parameter selection  $\lambda$  and show that with a fixed value of  $\lambda$  we can't obtain a satisfactory image segmentation, so for best image segmentation  $\lambda$  can be varied according to the image. Another critical problem is if we gave different value of  $\lambda$  we can obtain different segmentation for the same image. We can take the example cited above:

In graph cut image segmentation, the parameter  $\lambda$  is used to weight the region and boundary terms. In Ref. [19] Boykov and Kolmogorov have studied the sensitivity of selection of  $\lambda$  applied to different images with a fixed value of  $\lambda$  cannot give satisfactory results.

Figure 5 shows that in the interval  $\lambda = [10, 280]$  the image segmentation obtained is presented in (b); for  $\lambda = 290$  we can say that it is the best segmentation using graph cuts algorithm; and beyond with  $\lambda = 300$  can have the same segmentation obtained when  $\lambda$  belongs to the rage  $[10, 280]$ .

However, by combining the two methods mentioned above, the problem of choosing  $\lambda$  disappears completely when the choice of number of classes occurs; we can obtain a clearer and finer segmentation for brain images than the application of standard graph cuts algorithm only. We can distinguish segmented brain




Fig. 4. (a) Original brain image contain tumor. (b) The segmentation result by graph cuts algorithm (max flow). (c) Final segmentation result using graph cuts combined with automatic histogram thresholding.


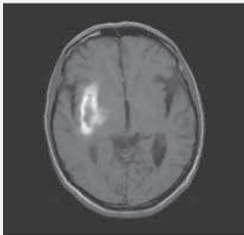


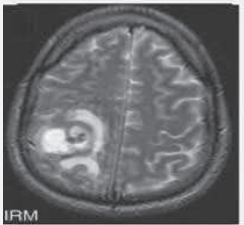

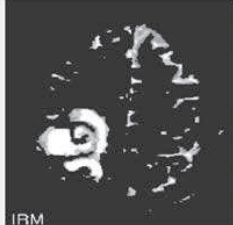
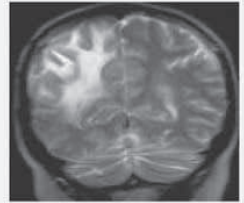
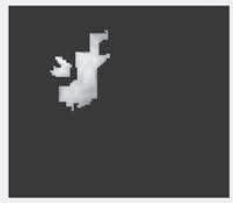

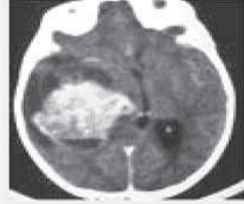
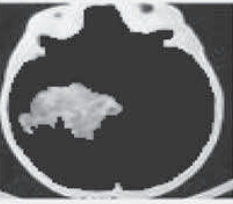

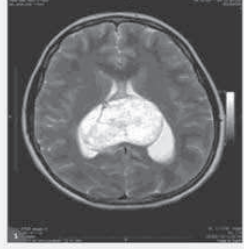
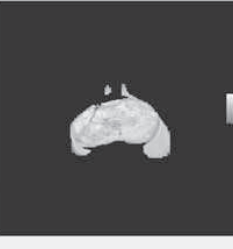
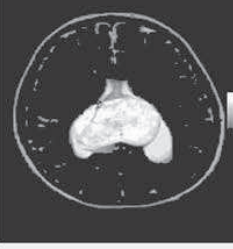
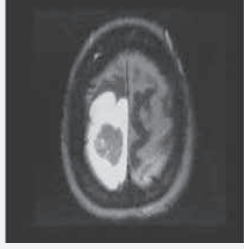






Fig. 5. (a) Original brain image contain tumor. (b) The segmentation result by graph cuts algorithm (max flow) with  $\lambda = 10$ . (c) The segmentation result by graph cuts algorithm (max flow) with  $\lambda = 290$ . (d) The segmentation result by graph cuts algorithm (max flow) with  $\lambda = 300$ .

Table I. (a) Original brain image contain tumor. (b) The segmentation result by graph cuts algorithm (max flow). (c) Final segmentation result using graph cuts combined with automatic histogram thresholding.

	(a)	(b)	(c)
1			
2			
3			
4			
5			
6			



**Fig. 6.** (a) Original brain image contain tumor. (b) The segmentation result by graph cuts algorithm (max flow). (c) Final segmentation result using graph cuts combined with automatic histogram thresholding with more of classes. (d) Final segmentation result using graph cuts combined with automatic histogram thresholding with less of classes.



**Fig. 7.** (a) Original brain image contain tumor. (b) The segmentation result by graph cuts algorithm (max flow). (c) Final segmentation result using the proposed method.

tumors with their different gray levels presented in the original image, so in the diagnosis help is almost perfect and we obtained good performances of segmentation.

We evaluate the segmentation performance of the proposed method in comparison with Boykov-Kolmogorov's algorithm.<sup>20</sup> We compared different brain images and the final results of image segmentation are better than graph cuts segmentation only.

Several brain images segmentation are presented in Table I, we have chosen 6 images reaches any brain tumors, we have shown segmentation results by graph cuts algorithm only and the final segmentation result using graph cuts combined with automatic histogram multilevel thresholding.

The challenge is to extract objects of interest from complex background, Table I shows image segmentation comparison result, the proposed method has a more accurate segmentation and more details on tumors extract for diagnosis help. For example there are some details that are neglected in standard graph cut such as in Table I, or they may be powers clearly using the proposed method even for images contain weak boundaries due to poor contrast.

Figure 6 shows a failure example; we can't extract clearly the brain tumor in (d) and at the same time segmentation obtained in (c) is the same thing as segmentation obtained in (b) with standard graph cuts algorithm; because for the brain image (a) background and foreground have a looks grayscale so it can assigned as the same label because of the connecting regions of object and background have similar grayscale and we confound between them and consequently image segmentation become hard.

But there is another problem to deal, it is the problem of time, our approach remains at least a little slow compared to other

algorithms applied because it depends to the initial segmentation step as a pre-segmentation to partition the image into regions is the automatic multilevel thresholding segmentation and the user input information as select foreground pixels and background pixels is an important factor to get desirable segmentation. Also, another factor plays an important role on the speed of the proposed method is the size of the image, for images of large size, the proposed algorithm still takes more seconds to display the result, and this is not the case when it comes to images of small size.

An example for colour image is shown in Figure 7, where we have applied the proposed method, we can also obtained better segmentation but in grayscale, it is clear that the difference results between (b) and (c) is important, we can distinguish the boundaries and the tumors regions in grey scale in (c), however in (b) with using graph cuts algorithm we confuse between the regions witch have the same grayscale. We will investigate how to incorporate these methods into our work in the future.

## 5. CONCLUSION

The various methods of segmentation offer several ways to segment an image. In this paper we have proposed a method of segmentation of brain tumors, based on the combination between two algorithms graph cuts and automatic histogram multi thresholding for initial segmentation. The parameter  $\lambda$  has no influence for the segmentation, so our method gives better and clear results than those obtained from standard graph cuts algorithm only. A comparison between different brain images segmentation show the effectiveness and precision.

## References and Notes

1. D. Greig, B. Porteous, and A. Seheult, Exact maximum a posteriori estimation for binary images. *Journal of the Royal Statistical Society, Series B* 51, 271 (1989).
2. D. R. Karger and C. Stein, A new approach to the minimum cut problem. *J. ACM* 43, 601 (1996).
3. Y. Boykov and F.-L. Gareth, Graph cuts and efficient N-D image segmentation. *International Journal of Computer Vision* 70, 109 (2006).
4. B. V. Cherkassky, On implementing the push-relabel method for the maximum flow problem. *Algorithmica* 19, 390 (1997).
5. M. Péchaud, Introduction aux GraphCuts en Vision par Ordinateur (2007).
6. B. Peng, L. Zhang, D. Zhang, and J. Yang, Image segmentation by iterated region merging with localized graph cuts (2011).
7. S. Demange, Minimisation d'énergie par graph-cuts appliquée à la segmentation d'images et à la stéréoscopie (2004).
8. N. Lermé, F. Malgouyres, L. Létocart, and J.-M. Rocchisani, Une méthode de réduction exacte pour la segmentation par graph cuts (2011).
9. N. Abdmouleh, V. Chen, and S. Ruan, Interactive segmentation of interest objects image by graph cuts approach (2011).
10. K. Housni, D. Mammass, and Y. Chahir, *Extraction de Zones d'Intérêt par Graph Cuts 5th International Conference: Sciences of Electronic, Technologies of Information and Telecommunications* (2009).
11. V. Chen and S. Ruan, Segmentation spectrale d'images IRM cérébrales par la méthode des coupes de graphes.
12. M. Kunt, *Traitement de l'information: Volume 2 traitement numérique des images* (1993).
13. J. Lecoeur, Segmentation d'IRM cérébrales multidimensionnelles par coupe de graphe (2010).
14. D. Grosgeorge, C. Petitjean, and S. Ruan, Segmentation d'images par coupe de graphe avec a priori de forme (2012).
15. A. Khayruddin, Segmentation and Image Detection of Region of Interest Medical Image Processing Course (2011).
16. N. Senthilkumaran and R. Rajesh, Brain image segmentation. *International Journal of Wisdom Based Computing* 1 (2011).
17. M. Kass, A. Witking, and D. Terzopoulos, Snakes: Active contour models. *Int. J. Comput. Vis.* 1, 321 (1988).
18. V. Caselles, R. Kimel, and G. Sapiro, Geodesic active contours. *Int. Journal of Computer Vision* 22, 61 (1997).
19. Y. Boykov and V. Kolmogorov, *An Experimental Comparison of Min-Cut/Max-Flow Algorithms for Energy Minimization in Vision in IEEE Transactions on PAMI* 26, 1124 (2004).
20. Y. Boykov and M. P. Jolly, Interactive graph cuts for optimal boundary and region segmentation. *International Conference on Computer Vision I* (2001), pp. 105–112.
21. J. Liu, J. Sun, and H.-Y. Shum, Paint selection. *Siggraph* (2009).
22. W. Tao, H. Jin, and L. Liu, A New Image Thresholding Method Based on Graph Cuts, *IEEE* (2007), pp. 605–608.
23. N. B. Ukunde, Sanjv K. Shrivastava, and S. N. Ukunde, Performance evaluation of image segmentation using histogram and graph theory. *International Journal of Scientific and Research Publications*, ISSN 2250–3153 (2012).
24. J. Liu, W. Li, and Y. Tian, Automatic thresholding of gray-level pictures using two-dimension otsu method, *Circuits and Systems, Conference Proceedings, International Conference on, China* (1991), Vol. 1, pp. 325–327.
25. R. B. Ohlander, Analysis of natural scenes, Ph.D. Thesis, Carnegie Institute of Technology, Department of Computer Science, Carnegie-Mellon University, Pittsburgh, PA (1975).
26. F. Kurugollu, B. Sankur, and A. E. Harmanci, Color image segmentation using histogram multithresholding and fusion. *Image and Vision Computing* 19, 915 (2001).
27. E. Zahara, F. J. Chang, and G. Bilbro, Optimal multi-thresholding using a hybrid optimization approach (2005).
28. N. Otsu, A threshold selection method from grey-level histograms. *IEEE Trans. System, Man, and Cybernetics* 9, 377 (1979).
29. S. S. Reddi, S. F. Rudin, and H. R. Keshavan, An optimal multiple threshold scheme for image segmentation. *IEEE Trans. System Man and Cybernetics* 14, 661 (1984).

Received: 26 December 2013. Accepted: 2 September 2013.