REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITE MOULOUD MAMMERI, TIZI-OUZOU
FACULTE DE GENIE ELECTRIQUE ET DE L'INFORMATIQUE
DEPARTEMENT D'ELECTRONIQUE

MEMOIRE DE MAGISTER EN ELECTRONIQUE

OPTION : ***Télédétection***

Présenté par :

Mme. SLIMANI Kahina épouse REBAH

THEME :

Segmentation d'images IRM par une technique basée sur le détecteur multi échelles de Canny.

Devant les membres du jury :

Président :	Mr. ZIANI Rezki	Maître de conférences UMMTO
Rapporteur :	Mr. AMEUR Soltane	Professeur UMMTO
Examinateurs :	Mr. LAGHROUCHE Mourad	Maître de conférences UMMTO
	Mme. AMEUR Née MAZOUZI Zohra	Maître de conférences UMMTO
	Mr. LAHDIR Mourad	Maître de conférences UMMTO

Soutenu le : 29 / 06 / 2010

Résumé

Dans ce travail, nous présentons une segmentation d'image par résonance magnétique(IRM) basée sur le détecteur multi-échelle de canny. L'objectif visé est d'extraire une tumeur dans une IRM du cerveau d'une femme de 74 ans atteinte d'une tumeur (méningiome frontale). Nous proposons un schéma de représentation multi-échelle en utilisons les maxima d'ondelette.la transformation en ondelette est obtenu par projection orthogonal de l'image sur les espaces affines obtenu à partir de la base d'ondelette, on parle d'espace d'approximation et d'espace de detail.les valeurs des images d'approximation et de détail sont calculées en utilisons un paramètre de dilatation et un paramètre de translation. Nous utilisons une transformation en ondelette discrète dyadique sans décimation. Ce signifie que le coefficient de dilatation utilisé est 2, l'image résultante est de la même taille que l'image originale. Apres la décomposition multi-échelle, on dispose d'un ensemble d'images d'approximation et d'images de détails. A partir de cette décomposition on calcul le module des images de détails. En extrait ensuite les maxima locaux de ces modules. Ces derniers constituent une décomposition en contours multi-échelle qui peut être traitée par les techniques classiques d'étude de contour. Pour cela nous calculons la décomposition en gradient multi-échelle suivant l'approche de canny. La détection de Canny repose sur une dérivée première d'une gaussienne. Un contour est détecté lorsque le module du gradient est maximal dans la direction du gradient. De plus, avant de calculer le gradient, il est nécessaire de lisser l'image par un noyau de convolution. Ce dernier est la dérivée d'une gaussienne.

Le module des coefficients de détails est en relation direct avec le gradient de l'image.les maxima locaux correspondent aux zones de forte transition de l'image. Alors on dispose d'un ensemble de maxima à différentes échelles, l'objectif est de chainer les contours à travers les échelles pour ne garder que les contours les plus significatifs.

Cette méthode est applique aux IRM d'un cerveau sein ainsi que sur des images d'un cerveau atteint d'une tumeur, on comparant les deux résultats en aperçois bien la tumeur.

Mots-clés : segmentation, IRM, tumeur, détecteur de canny, multi-échelle, ondelette.

REMERCIEMENTS

Le travail que nous avons l'honneur de présenter, a été effectué au sein du laboratoire d'analyse et de modélisation des phénomènes aléatoires (LAMPA), sous la direction de Mr AMEUR Soltane professeur à l'université UMMTO de Tizi-Ouzou.

Mes remerciements vont en premier lieu à mon directeur de mémoire, monsieur, AMEUR Soltane, pour la qualité de son encadrement. Ses conseils, son enthousiasme, sa disponibilité, ses encouragements, son attention, du début à la fin de ce mémoire ont été pour moi une aide précieuse et une source d'équilibre pour la réalisation de ce travail. Pour tout cela, je le remercie vivement.

Je remercie également monsieur ZIANI Rezki, Maître de Conférences à l'UMMTO pour m'avoir fait l'honneur de présider ce jury.

Je remercie vivement monsieur LAGHROUCHE Mourad, Maître de Conférences à l'UMMTO. C'est avec un énorme plaisir que je le vois prendre part à ce jury.

Mes sincères remerciements à Madame AMEUR Zohra, Maître de conférences à l'UMMTO, d'avoir aimablement accepté de participer au jury de ce mémoire.

Je tien aussi à exprimer mes vifs remerciements à monsieur LAHDIR Mourad, Maître de conférences à l'UMMTO, d'avoir accepté de faire partie de ce jury.

Je tiens à remercier chaleureusement tous les membres du laboratoire LAMPA, et tous ceux qui ont contribué, de près ou de loin, à concrétiser ce travail.

Ces remerciements ne seraient pas complets si je ne les associais pas à mon Mari qui m'a soutenu pendant toutes ces années.

Je souhaiterais dédier ce mémoire à mes parents et à ma fille.

SOMMAIRE

Introduction **1**

CHAPITRE 1 : Anatomie cérébrale et principe de l'IRM

1.1. Préambule **3**

1.2. Anatomie du cerveau **4**

1.2.1. La substance grise **4**

1.2.2. La substance blanche **4**

1.2.3. Le liquide céphalo-rachidien **5**

1.2.4. Les méninges **5**

1.3. Observation du cerveau **6**

1.4. La tumeur **6**

1.4.1. Définition **6**

1.4.2. Le méningiome frontal **7**

1.5. Acquisition d'images **7**

1.5.1. L'imagerie par résonance magnétique (IRM) **7**

1.5.1.1. Principe de la résonance magnétique nucléaire (RMN) **8**

1.5.1.2. Les différentes pondérations **12**

a. Images pondérées en T1, T2 ..... **13**

b. L'image de densité de protons ou ρ-pondérée **13**

1.6. La formation des images IRM 15

1.6.1. Excitation sélective (sélection de la coupe) 15

a. l'orientation 15

b. le niveau de la coupe 16

c. l'épaisseur de la coupe 16

1.6.2. Codage par la phase 16

1.6.3. Codage par la fréquence 17

1.7. L'imageur IRM 20

1.8. Le produit de contraste en IRM 21

1.8.1. Le produit de contraste T1 21

1 .8.2.Le produit de contraste T2 21

1 .9. Incertitudes et imprécisions des images IRM 21

1.9.1. Le système d'acquisition 22

1.9.2. Phénomène de dérive 23

1.9.3. Effet de volume partiel 23

1.10. Discussion 24

CHAPITRE 2 : Méthodes de segmentation d'images IRM

2.1. Préambule 25

2.2. Généralités sur la segmentation 26

2.3. Définition numérique de la segmentation d'images 26

2.4. Méthodes de segmentation d'images 27

2.4.1. Approches régions 27

2.4.1.1. Les méthodes de classification 28
2.4.1.2. Les méthodes de type croissance de région 28

2.4.2. Méthodes basées sur l'analyse de texture 28

2.4.3. Approche frontières 29

2.4.3.1. Approche contours 29

a. Les contours actifs 30
b. Les approches dérivatives 31
b.1. Approche gradient 31

b.1.1. Calcul direct 32

b.1.2. Operateur de Robert 32

b.1.3. Opérateur de Sobel 33

b.1.4. Opérateur de Prewitt 34

b.1.5. L'approche Laplacien 35

c. L'approche de Canny 36
c.1. Bonne détection 36

c.2. Bonne localisation 36

c.3. Réponse unique 37

c.4. L'algorithme de détection de contour basé sur l'approche de Canny 37

c.4.1. Le filtrage Gaussien 38

c.4.2. Déterminer la magnitude du gradient et la direction du gradient 38

c.4.3. Suppression de non-maxima 39

2.5. Discussion 40

CHAPITRE 3 : Segmentation d'images par le détecteur multi échelles de canny

3.1. Préambule 41

3.2. La transformée de Fourier 42

3.3. Eléments de la théorie des Ondelettes 44

3.3.1. Définition des ondelettes 44

3.3.2. Transformation en ondelette continue(TOC) 44

3.3.3. Ondelettes 2D directionnelle 45

3.3.4. Discrétisation 46

3.4. Analyse Multi résolution (AMR) 47

3.5. Algorithme à trous 48

3.6. Algorithme par convolution en cascade B-spline 50

a. La B-spline 52

a.1. Définition monodimensionnelle 52

a.2. B-spline discrète 52

3.7. Le détecteur multi-échelles de Canny 53

3.8. Maximum local 56

3.8.1. Cas monodimensionnel 56

3.8.2. Cas bidimensionnel 56

3.9. Le chaînage 58

3.10. Les différentes étapes du détecteur multi échelle de canny 59

3.11. Discussion 60

CHAPITRE 4 : Applications du détecteur multi échelles de canny à des images IRM

4.1. Préambule 61

4.2. Description de l'algorithme 62

4.2.1. Conversion de l'image en matrice 62

4.2.2. Convolution en cascade de l'image par un masque B-spline θ 62

4.2.3. Dérivations : convolution par Dx et Dy 62

4.2.4. Calcul du module et de l'orientation du gradient de l'image à partir des coefficients d'ondelette horizontaux et verticaux. 63

4.2.5. Chainage des maximas locaux et détection de point de contours 63

4.3. Résultats obtenus de l'application de notre algorithme à des images Test 64

4.3.1. Application à l'image Fields 64

4.3.1.1. Singularités verticales 64

4.3.1.2. Singularités horizontales 64

4.3.1.3. Cartes des modules et des orientations du gradient 65

4.3.1.4. Maximas locaux du gradient 65

4.3.1.5. Résultat obtenu après chainage des maximas locaux du gradient 66

4.3.2. Application à l'image Cameraman 66

4.3.2.1. Singularités verticales 67

4.3.2.2. Singularités horizontales 67

4.3.2.3. Cartes des modules et des orientations du gradient 68

4.3.2.4. Maximas locaux du gradient 68

4.3.2.5. Résultat obtenu après chainage des maximas locaux du gradient 69

4.3.3. Application à l'image Suzan 69

4.3.3.1. Singularités verticales 70

4.3.3.2. Singularités horizontales 70

4.3.3.3. Cartes des modules et des orientations du gradient 70

4.3.3.4. Maximas locaux du gradient 71

4.3.3.5. Résultat obtenu après chainage des maximas locaux du gradient 71

4.2. Présentation des données 72

4.2.1 Image du cerveau sain 72

4.2.2. Image du cerveau atteint d'un méningiome frontal 73

4.4. Résultats obtenus de l'application de notre algorithme sur une image IRM du cerveau sain 74

4.4.1. Lissage de l'image 74

4.4.2. Singularités verticales 75

4.4.3. Singularités horizontales 76

4.4.4. Module du gradient de l'image 77

4.4.5. Orientations du gradient de l'image 78

4.4.6. Maximas locaux 79

4.4.7. Résultat après chainage 80

4.4.8. Interprétation des resultats 80

4.5. Résultat obtenus par l'application de notre algorithme sur l'IRM du cerveau atteint d'un méningiome 81

4.5.1 Lissage 81

4.5.2 Singularités verticales 82

4.5.3 Singularités horizontales 83

4.5.4 Module du gradient de l'image 84

4.5.5 Orientations du gradient de l'image 85

4.5.6. Maximas locaux 86

4.5.7. Résultat après chainage 87

4.5.8.Interprétation des resultats 87

4.5.9.comparaison des résultatas obtenus avec l'approche de canny classique 87

Conclusion 89

Bibliographie

Introduction

INTRODUCTION

La segmentation des tissus du cerveau à partir de données médicales est une problématique importante pour de nombreuses applications, notamment celles liées au diagnostic [1][2].

La segmentation est une opération de traitement d'image qui a pour but de partitionner une image en régions homogènes composées de pixels ayant les mêmes caractéristiques selon des critères prédéfinis. En IRM (imagerie par résonance magnétique) cérébrale elle permet de différencier les tissus, les structures anatomiques, et/ou les lésions et tumeurs.

La plupart des méthodes de segmentation d'images IRM publiées dans la littérature nécessite l'ajustement plusieurs paramètres de contrôle afin d'obtenir de bon résultats [6][9]. Les approches « région »et les approches « contour » sont les plus utilisées pour la segmentation des images IRM.

Pour la segmentation d'image IRM en région, on retrouve dans la littérature diverses méthodes tel que celles basées sur les K-means [14] qui permet de classifier les structures sain du cerveau dans des classes différentes et la tumeur dans une autre classe mais cette méthode présente un choix de nombre de classe. Les méthodes de croissance de régions qui permettent aussi bien la segmentation de structures saines [15][16] que la segmentation de pathologiques[17][18], néanmoins leur inconvénient est lié à la disposition des germes initiaux. Les méthodes basées sur l'analyse de la texture [19][20] ; qui reste cependant peu performantes car il n'est pas facile de trouver des modèles de texture qui peuvent séparer tissus normaux et anormaux.

Pour la segmentation d'image IRM en contours on retrouve les approches dérivatives et les contours actifs [13] malgré que cette dernière s'avère efficace pour

La segmentation anatomique du cerveau, elle reste relativement sensible à son initialisation.

Dans ce travail, nous présentons une méthode de segmentation d'image (IRM) basée sur le détecteur multi-échelle de canny. L'objectif visé est d'extraire une tumeur dans une

IRM du cerveau atteint d'une tumeur (méningiome frontale). Nous proposons un schéma de représentation multi-échelle en utilisant les maximas d'ondelettes.

Notre mémoire est structuré en cinq chapitres :

Dans le premier chapitre nous donnerons le principe de l'imagerie par résonance magnétique(IRM) et une description de l'anatomie du cerveau afin de comprendre les images utilisées.

Dans le deuxième chapitre nous décrivons les principales méthodes de segmentation publiées dans la littérature.

Le troisième chapitre est consacré à la description du détecteur multi échelle de canny que nous avons développé..

Dans le quatrième chapitre nous donnons les résultats expérimentaux obtenus en appliquant notre technique à deux images représentant respectivement un cerveau sain et un cerveau atteint d'une tumeur.

Chapitre 1

Anatomie cérébrale et principe de L'IRM

CHAPITRE 1

ANATOMIE CEREBRALE ET PRINCIPE DE L'IRM

1.1. Préambule

La segmentation des tissus du cerveau à partir de données médicales est une problématique importante pour de nombreuses applications [1][2], notamment celles liées au diagnostic et au suivi de maladies neurodégénératives. Une des techniques les plus utilisées pour détecter les tumeurs cérébrales consiste en l'utilisation de l'imagerie par résonance magnétique (IRM).

L'imagerie par résonance magnétique nucléaire est une technique en développement depuis une cinquantaine d'années. Le phénomène physique a été élaboré en 1946 par BLOCH et PURCELL [56].

Les premiers développements en imagerie datent des années 1973 et les premières images chez l'homme ont été réalisées en 1979. Aujourd'hui, l'IRM est devenue une technique majeure de l'imagerie médicale moderne.

Dans ce chapitre nous introduirons le principe et les spécificités des images obtenues via l'imagerie par résonance magnétique et nous décrirons les diverses parties du cerveau.

1.2. Anatomie du cerveau

Le cerveau est la partie la plus volumineuse du système nerveux central, il est composé de substance (ou matière) grise et de substance blanche, le tout baigne dans un liquide appelé liquide céphalo-rachidien(LCR) (voir figure.1.1).Le cerveau est entouré de couches protectrices appelées les méninges [1].

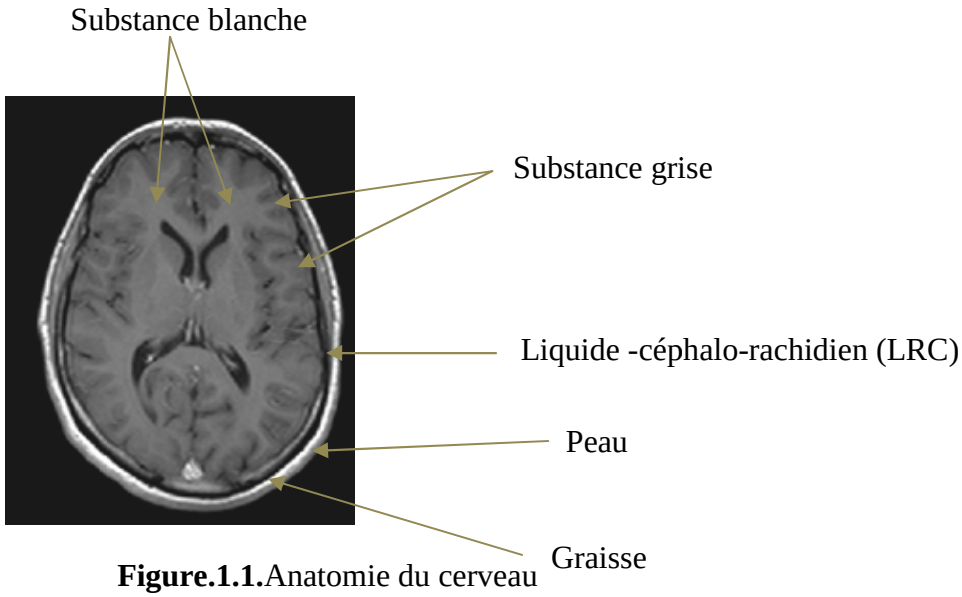

Figure.1.1. Anatomie du cerveau

1.2.1. La substance grise

La substance grise est essentiellement composée de neurones et elle constitue le siège de l'activité cérébrale [2].

1.2.2. La substance blanche

La substance blanche est la partie interne du cerveau, elle contient les liaisons entre les neurones [2].

1.2.3. Le liquide céphalo-rachidien

Le liquide céphalo-rachidien est une substance transparente constituée de 99% d'eau. Il forme un coussin protecteur pour le système nerveux central (SNC) et le nourrit [1].

1.2.4. Les méninges

Le cerveau est entoure de couches protectrices appelées les méninges. Elles sont constituées de trois membranes successives [1], voir figure1.2.

- la plus interne de ces membranes est la pie-mère, fine, compacte, elle contient les structures veineuses qui ramènent le sang du cerveau vers le cœur.
- la membrane intermédiaire est l'arachnoïde, ainsi appelée en raison de sa ressemblance avec une toile d'araignée (le LCR circule entre celle-ci et la pie-mère).
- la membrane la plus externe est la dure-mère, dure et résistante, formée de tissu conjonctif qui protège les couches sous-jacentes des os qui les entourent.

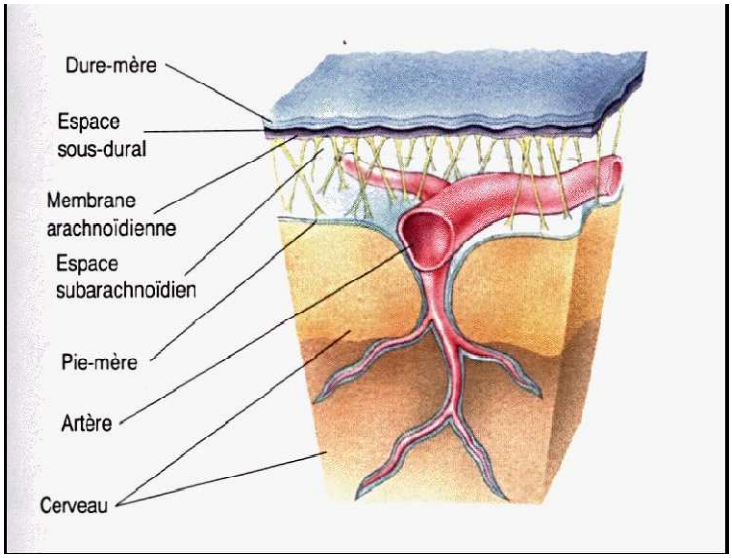

Figure.1.2. Anatomie des méninges.

1.3. Observation du cerveau

L'observation par des coupes en deux dimensions du cerveau peut être effectuée selon plusieurs angles de vue. Ainsi, on distingue trois axes anatomiques pour réaliser les coupes [2].

- ✓ **Coupes axiales** : Ces coupes correspondent quasiment à un plan horizontal. En imagerie de résonance magnétique, elles correspondent à un plan perpendiculaire à l'axe du champ magnétique principal.
- ✓ **Coupes sagittales** : Ces coupes sont prises dans des plans parallèles au plan inter-hémisphérique. Il s'agit de vues latérales du cerveau.
- ✓ **Coupes coronales** : Ce sont des coupes perpendiculaires aux coupes axiales et sagittales, elles correspondent à des vues de face du cerveau.

La Figure**.1.3** illustre les différentes coupes

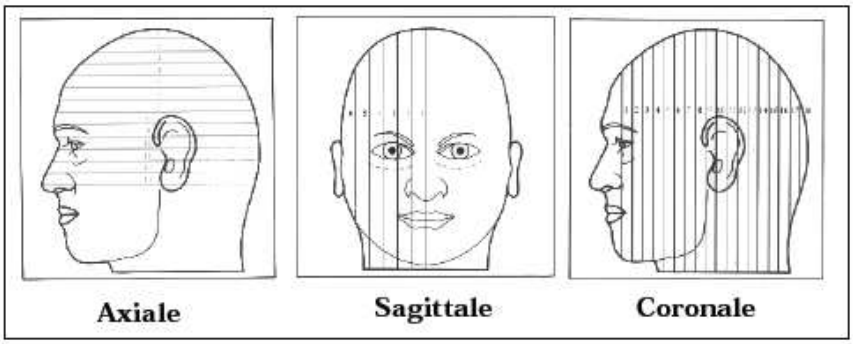

Figure.1.3. Les trois axes de coupe pour la visualisation du cerveau.

1.4. La tumeur

1.4.1. Définition

La tumeur désigne une multiplication tissulaire ou cellulaire anormale, non inflammatoire, échappant aux mécanismes de régulation de l'organisme [3].

L’expression « cancer du cerveau », ou « tumeur du système nerveux central », regroupe plusieurs formes de tumeurs susceptibles de se développer dans le cerveau : soit à partir d’une cellule du cerveau lui même, soit d’une cellule métastasique exportée d’un cancer situé dans une autre partie du corps.

1.4.2. Le méningiome frontal

Le méningiome est une tumeur nerveuse développée à partir des méninges. Il s’agit d’une tumeur bénigne qui se développe très progressivement et de façon très lente, pendant de nombreuses années [4].

Le méningiome peut être localisé à différents endroits. Quand il s’agit d’un méningiome frontal, cela signifie simplement qu’il est localisé à proximité du lobe frontal du cerveau.

1.5. Acquisition d’images

L’imagerie médicale joue un rôle très important dans l’observation in vivo chez l’humain. Elle permet en effet d’observer la structure et le comportement d’organes grâce à un ensemble important de techniques d’acquisition : imagerie par résonance magnétique (IRM), scanographie par rayon X, échographie . . . etc.

Dans le cadre de l’étude du cerveau, l’imagerie par résonance magnétique est un outil de diagnostic clinique et de recherche extrêmement puissant car il permet de discriminer les différents tissus et autorise plusieurs modalités (T1, T2,…etc.) ayant chacune des propriétés particulières [6].

1.5.1. L'imagerie par résonance magnétique (IRM)

L'imagerie par Résonance Magnétique (IRM) est une technique d'imagerie qui, dans le secteur médical, permet de produire des images de haute qualité de l'intérieur du corps humain.

L'IRM est basée sur les principes de la Résonance Magnétique Nucléaire (RMN), une technique utilisée par les scientifiques pour obtenir des informations chimiques et physiques sur les molécules. La technique fut appelée IRM plutôt que IRMN à cause de la connotation négative associée au terme nucléaire dans les années 1970 [5] [7] [8].

1.5.1.1. Principe de la résonance magnétique nucléaire (RMN)

La RMN est basée sur l'absorption et l'émission d'énergie dans le domaine des radiofréquences du spectre électromagnétique. Elle nécessite l'emploi de champs magnétiques qui vont interagir avec certains noyaux stables (noyaux d'hydrogène) d'atomes qu'on peut rencontrer notamment au sein des systèmes biologiques.

En Imagerie par Résonance Magnétique, trois types distincts de champ magnétique seront utilisés: un champ magnétique statique intense (B_0), des gradients linéaires de champ magnétique ($G_{x,y,z}$) et des champs magnétiques oscillant (B_1) dans la gamme des radiofréquences (ondes radio dans la bande de 20 à 400 MHz) [6] [9].

Le champ magnétique statique généralement sert à «aimanter» l'organe, ou l'être humain qui le subit, il est d'amplitude de 0.2 à 3 Teslas. Lorsque l'échantillon biologique et, par voie de conséquence ses spins protoniques est plongé dans un champ magnétique statique B_0, il y a aimantation de l'échantillon et création d'une aimantation macroscopique M_0, (voir figure1.4, figure.1.5 et figure1.6).

Les gradients $G_{x,y,z,}$ de champ magnétique sont superposés à B_0 ce qui permet à chaque point de l'échantillon biologique de posséder sa propre fréquence de résonance, il suffira alors d'émettre une onde RF dont la fréquence sera ajustée sur la fréquence de Larmor à l'endroit de l'échantillon qu'on désire examiner pour récolter en retour un signal RM ne provenant que de cet endroit.

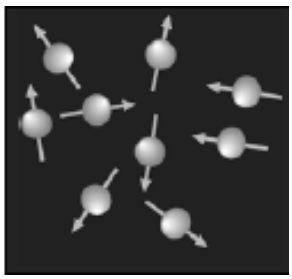

Figure.1.4. mouvement des Protons en absence de B_0

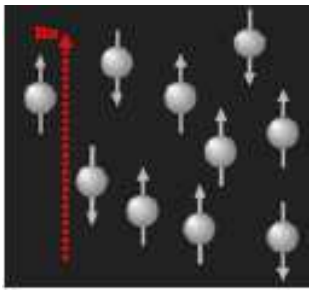

Figure.1.5. Mouvement des protons en présence de B_0

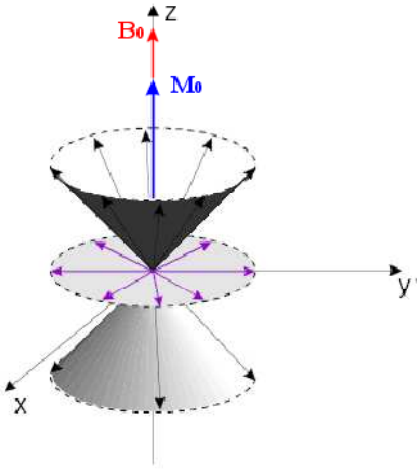

Figure.1.6. L'aimantation M_0

Dans l'échantillon, chaque spin précessionne autour de B_0 (voir figure.1.7) avec une vitesse angulaire de rotation ω_0 appelée pulsation de Larmor exprimée par:

$$\omega_0 = \gamma B_O \qquad (1.1)$$

Et, à cette vitesse de rotation associée la fréquence de Larmor, qui est exprimée par:

$$\nu_0 = (2\pi)^{-1}\,\omega_0 \qquad (1.2)$$

Le rapport gyromagnétique «γ»est une constante intrinsèque des noyaux.

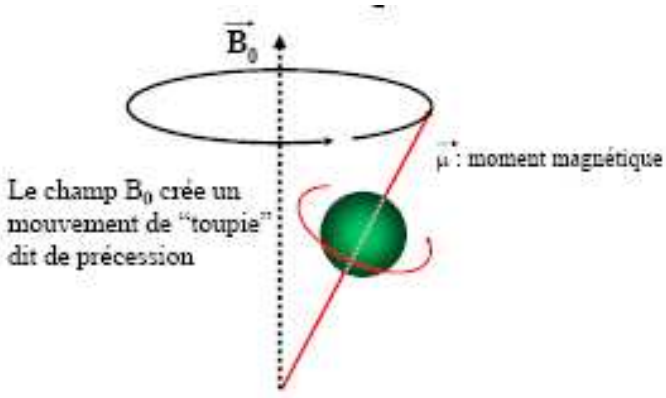

Figure.1.7. mouvement de précession

Grâce à une antenne émettrice, on émet une onde électromagnétique à la fréquence de Larmorω_0, alors on parviendra à perturber l'orientation de M_0. Ainsi, l'application momentanée de cette onde électromagnétique RF (impulsion RF) et plus particulièrement sa composante magnétique$\boldsymbol{B_1}$, va exciter les spins protoniques et faire tourner d'un certain angleθ , M_0 par rapport à B_0 [10] [11]**.** (figure.1.8)

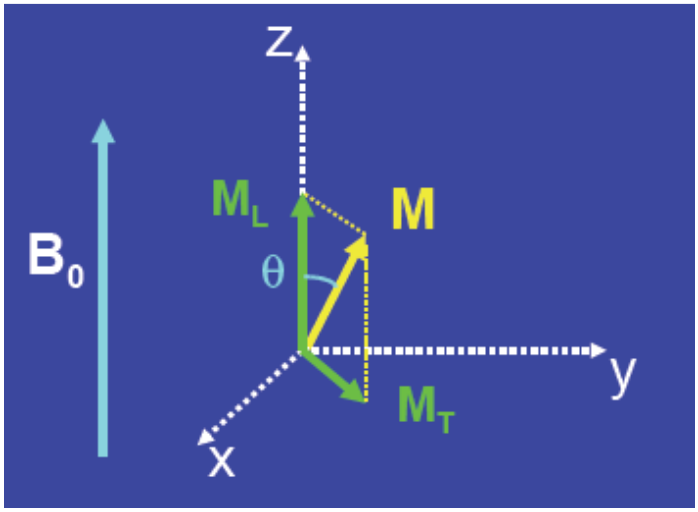

Figure.1.8.action du champ B_1 sur M_0

Cet angle de rotation de M_0 par rapport à B_0 est exprimé par:

$$\theta = \gamma B_1 \tau \qquad (1.3)$$

Où τ : est l'intervalle de temps pendant lequel l'impulsion RF est appliquée.

Deux cas particuliers de cet angle sont utilisés dans les séquences d'impulsions courantes, l'impulsions 90° et 180°, correspondant respectivement à M_0 perpendiculaire ou antiparallèle à B_0 [8]. Les deux impulsions sont représentées par la figure.1.9.

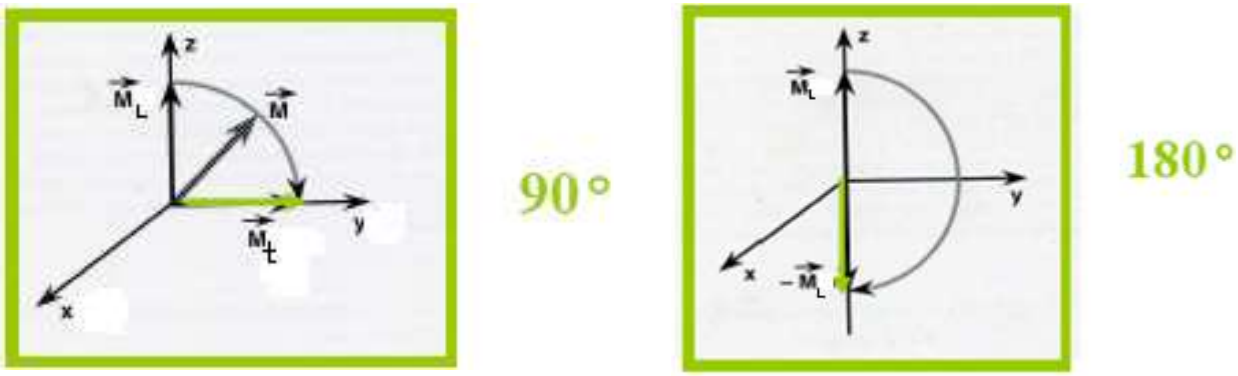

(a) **(b)**

Figure.1.9. les angles de basculement de M_0

(a) basculement de M_0 d'un angle $\theta = 90^0$

(b) basculement de M_0 d'un angle $\theta = 180^0$

A l'arrêt de l'impulsion radiofréquence l'aimantation cesse de précesser autour de B_0 et retrouve progressivement sa position d'équilibre selon B_0. La composante longitudinale M_l retourne à la valeur d'équilibre M_0 avec une constante de temps T_1 (temps de relaxation longitudinal ou temps de relaxation spin-réseau) et la composante transversale M_t perpendiculaire à B_0 s'annule avec la constante de temps T2 (temps de relaxation transversal ou temps de relaxation spin-spin).

Une bobine détecte la variation de flux dû à la précession de l'aimantation transversale M_t et on obtient au bord de la bobine un signal électrique sinusoïdal exponentiellement amorti avec la constante de temps T2, c'est le signal RMN ou signal de FID (Free Induction Decay). C'est ce signal qui est recueilli par les bobines de réception puis transformé en signal électrique [10], ce signal est représenté sur la figure1.10

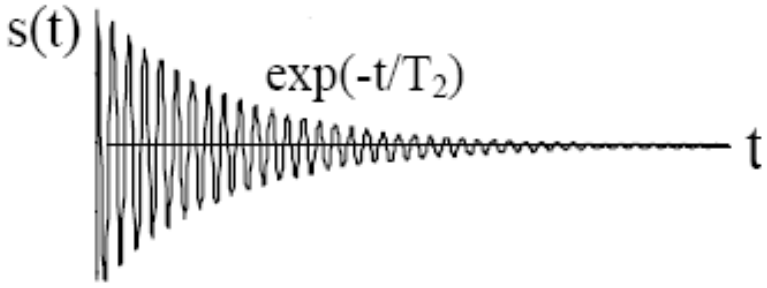

Figure.1.10. Signal FID (signal de précession libre) recueilli par les bobines réceptrices

1.5.1.2. Les différentes pondérations

Nous distinguons trois type de pondération : la pondération T1, la pondération T2 et la pondération en densité de protons, chacune des pondérations est liée aux différentes relaxations.

La figure.1.11illustre les différentes pondérations

La relaxation est liée à la dissipation d'énergie lors du passage des protons d'un état excité à un état d'énergie inférieure, cette énergie est échangée et absorbée par d'autres protons de l'échantillon .

Le temps de relaxation est le temps pour atteindre l'équilibre qui est régi par la relaxation thermique, ou la relaxation spin-réseau appelée la relaxation *T*1.

Le processus de relaxation *T*2 commence juste après l'absorption de l'énergie de l'onde, il résulte de la perte de concordance de phase entre protons tournant dans le plan transversal.

a. Images pondérées en T1, T2

Chaque proton d'un groupe atomique d'une molécule a sa propre valeur de *T*1 et de *T*2 (voir table1.1)[10], si bien que chaque tissu du corps a sa propre caractéristique de relaxation qui dépend de la valeur combinée de *T*1 et de *T*2. Le terme « pondération en *T*1 ou en *T*2 » est employé pour qualifier l'énergie du signal de la relaxation des spins décomposée suivant un axe parallèle au champ magnétique (relaxation longitudinale ou T1) ou un axe perpendiculaire au champ magnétique (relaxation transversale ou T2).

La modalité T1 permet d'observer les tissus du cerveau : matière blanche (MB), matière grise (MG) et le liquide céphalo-rachidien.

La modalité T2 ne permet pas de distinguer la matière grise de la matière blanche, mais met en évidence les lésions et le LCR.

Temps de relaxation	**Tissus cérébraux**					
	LCR	**MG**	**MB**	**Méninges**	**Muscle**	**graisse**
***T*1 (ms)**	**800-20 000**	**1090-2150**	**760-1080**	**500-2200**	**950-1820**	**200-750**
***T*2 (ms)**	**110-2000**	**61-109**	**61-100**	**50-165**	**20-67**	**53-94**

Table.1.1. Temps de relaxation de différents tissus cérébraux (B_0 = 1.5T)

b. L'image de densité de protons ou ρ-pondérée

Une image peut être produite en commandant le choix des paramètres pour réduire au minimum les effets du *T*1 et du *T*2, ayant pour résultat une image principalement pondérée en densité des protons appelée image de densité de protons (DP), ou image pondérée en ρ.

Le contraste en densité de protons est quantitativement dépendant du nombre de protons par unité de volume. Plus le nombre de protons dans une unité du tissu donnée est élevé, plus la composante transversale de l'aimantation est grande et plus le signal sur l'image de contraste en densité de protons est en hypo signal.

Réciproquement plus le nombre de protons dans une unité donnée du tissu est bas, moins la magnétisation transversale est importante et plus le signal sur l'image de densité de protons est en hyper signal.

Pour obtenir une image pondérée en densité de protons, il faut utiliser une valeur de TR.

(TR ≥ 2000 ms) beaucoup plus grande que le temps *T*1 spécifique du tissu, et une valeur de TR (TR ≤ 30ms) inférieure au temps *T*2 spécifique du tissu considéré.

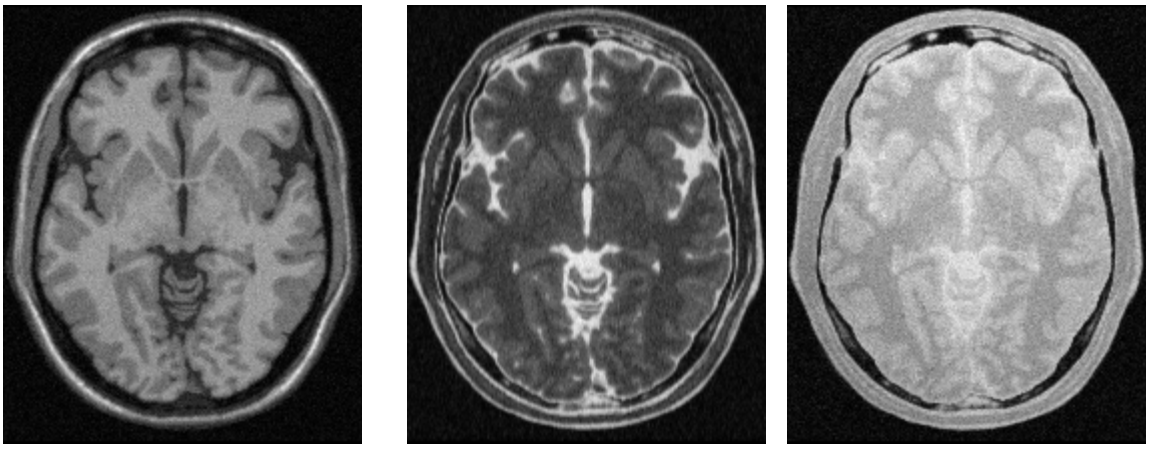

Pondération en T1 pondération en T2 pondération en ρ

Figure.1.11. Les différentes pondérations

- **Temps de répétition (TR)** : c'est l'intervalle de temps de répétition de l'onde d'excitation RF. L'intervalle entre les trains d'impulsions d'ondes RF s'appelle l'intervalle TR. Les TRs courts maximisent les différences dans la relaxation *T*1, produisant un fort contraste entre ces tissus. Si les TRs sont longs, ils réduisent au minimum les différences dans la relaxation *T*1, réduisant le contraste entre tissus [9].

- **Le temps d'écho (TE) :** représente le temps entre le milieu de l'application de l'impulsion
  $\theta = 90\circ$ et le sommet du signal d'écho dans les séquences Spin Echo (SE) [9].

1.6. La formation des images IRM

Pour réaliser une image IRM il est nécessaire de localiser le signal IRM, Il existe trois localisations du signal IRM à savoir : excitation sélective, Codage par la phase, Codage par fréquence.

1.6.1. Excitation sélective (sélection de la coupe)

En IRM l'impulsion d'excitation RF représente la fréquence de résonance, en présence de gradient de champ, seuls résonnent les éléments de volume dont la fréquence propre correspond à l'impulsion d'excitation, les paramètres de la coupe sélectionnée sont déterminés par les caractéristique de l'impulsion d'excitation et du gradient appliqué pendant son émission.

A la fin de l'impulsion RF 90° l'aimantation de tous les éléments de volume de la coupe est basculée dans le plan de mesure, alors que l'aimantation des coupes adjacentes restent parallèle au champ B_0.

Les paramètres de la coupe sélectionnée sont : l'orientation, le niveau de la coupe, l'épaisseur de la coupe.

a. l'orientation

La coupe sélectionnée est perpendiculaire à la direction du gradient appliqué pendant l'impulsion d'excitation RF, l'impulsion RF émise en présence de l'un des trois gradients Gx, Gy, Gz permet d'obtenir une orientation de coupe frontale, sagittale ou axiale.

Les trois plans de coupes sont représentés par la figure1 1.1

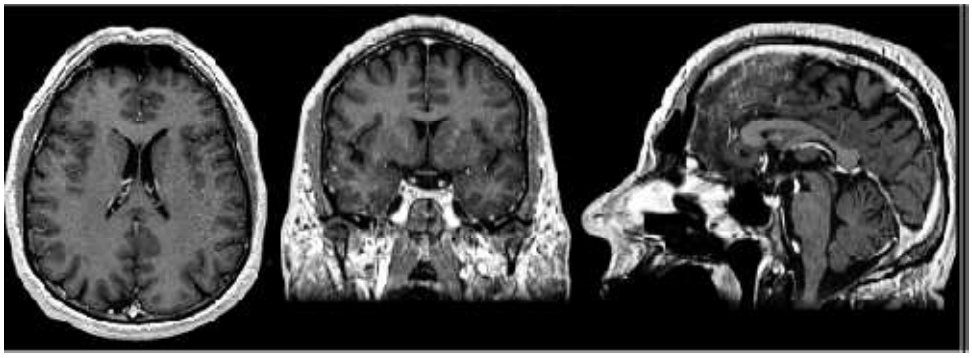

Figure.1.12. Plans axial, coronal et sagittal (de gauche à droite) sur une acquisition en T1.

b. le niveau de la coupe

Le niveau de coupe est déterminé par la fréquence de l'impulsion pour une intensité de gradient donné, une augmentation de la fréquence d'impulsion correspond à un déplacement du niveau de coupe dans le sens du gradient.

c. l'épaisseur de la coupe

L'épaisseur de la coupe est déterminée par l'intensité du gradient de sélection, la coupe est d'autant plus fine que le gradient est intense.

A l'intérieur du plan de coupe chaque pixel va être localisé selon son rang de ligne et de colonne dans une matrice

1.6.2. Codage par la phase

Application du gradient G_Φ selon la direction y va permettre le codage par la phase Φ_1, Φ_2, Φ_3 dans chacune des colonnes L_1, L_2, L_3 (figure1.13)

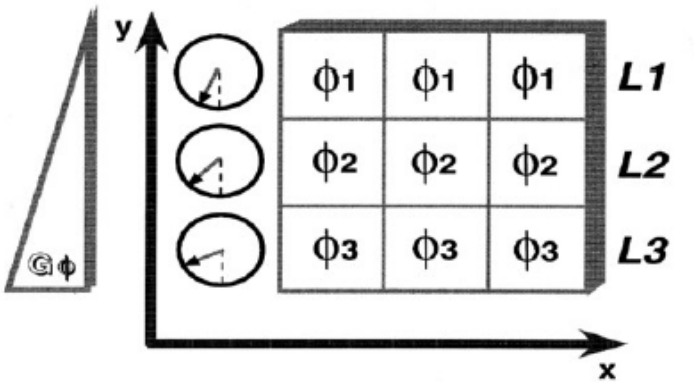

Figure.1.13. Codage par la phase

1.6.3. Codage par la fréquence

Application du gradient G_ω selon la direction x va permettre le codage par la fréquence $\omega_1, \omega_2, \omega_3$ dans chacune des colonnes c_1, c_2, c_3(Figure1.14).

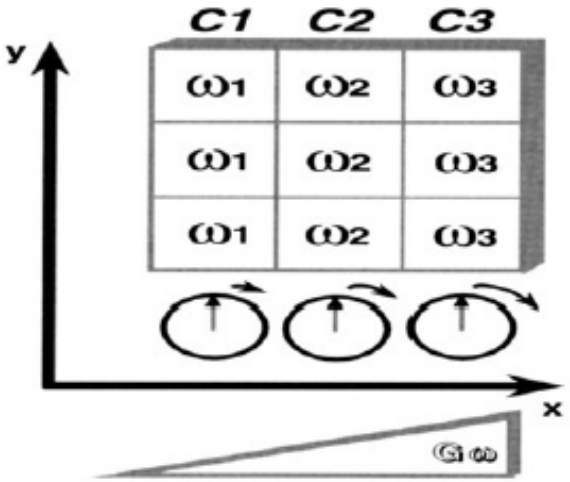

Figure.1.14. Codage par la fréquence

Pour la lecture des pixels ; Application de G_Φ puis G_w(Figure.1.15).

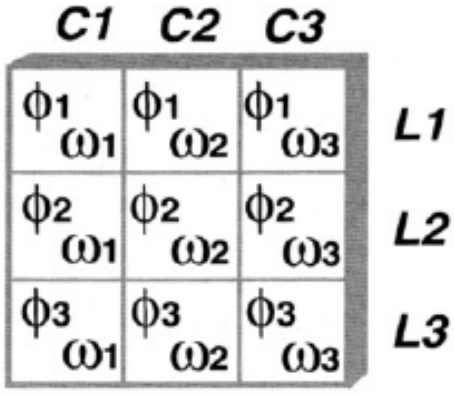

Figure.1.15. Codage de phase et fréquence

L'application d'un gradient de codage de phase et de fréquence ne permet d'obtenir l'information que d'une seule ligne de matrice , pour obtenir les lignes suivantes il faut relancer pour chaque ligne un gradient de phase et de fréquence avec un temps de repetition TR (voir figure1.16).

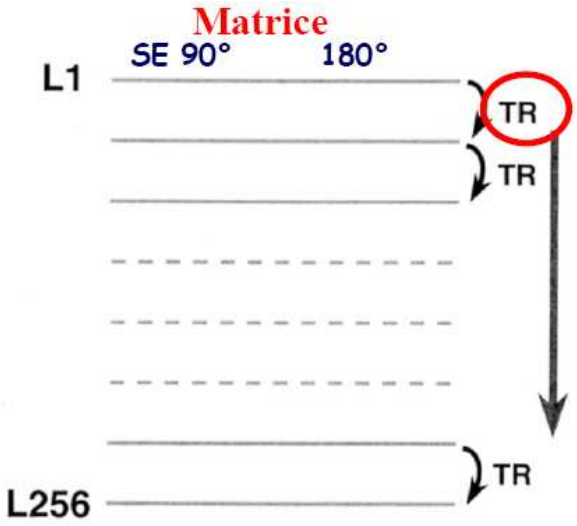

Figure.1.16.construction de la matrice

La durée d'une acquisition d'une image est donnée par l'équation (1.4) :

$$D = TR.N_{lignes}.N_{acc} \qquad (1.4)$$

Dont :

TR : temps de répétition

N_{lignes} : Nombre de ligne dans une matrice

N_{acc} : Nombre d'excitation

Pour construire l'image du plan, il est nécessaire de localiser spatialement les spins ce qui est réalisé à partir de la transformée de Fourier bidimensionnelle [10] (figure.1.17).

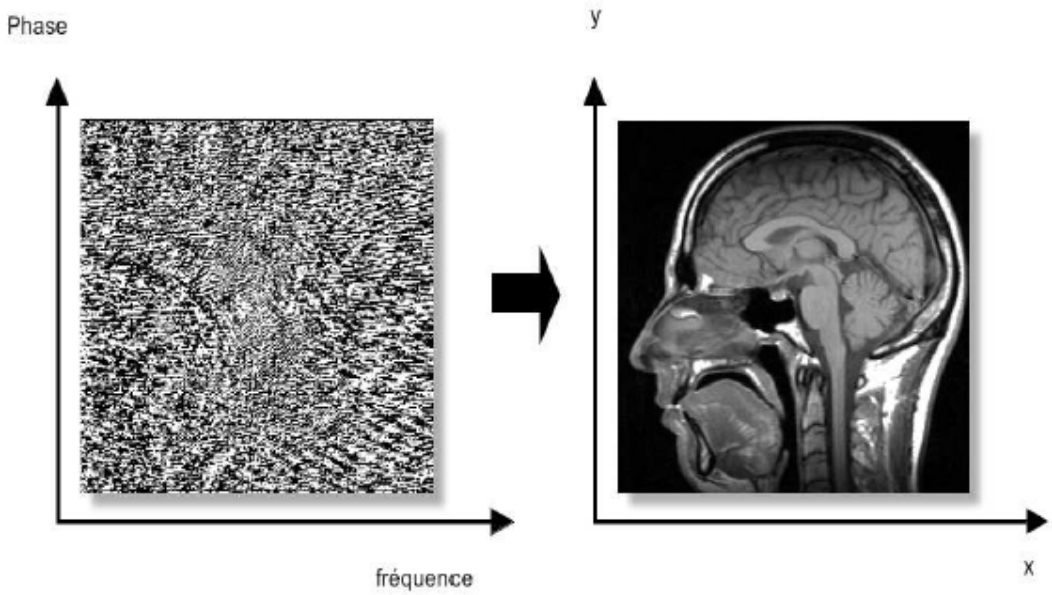

Figure.1.17. reconstruction d'une image IRM par transformée de Fourier bidimensionnelle

1.7. L'imageur IRM

L'imageur IRM est constitué [10] (figure1.18) :

- D'un aimant principal qui induit un champ intense$\overrightarrow{B_0}$ de 0 à 3 Tesla, il est constitué d'une bobine supraconductrice et d'un cryostat contenant de l'hélium (-269°C).
- De gradients de champ magnétique : Petits électroaimants disposé de part et d'autre du volume exploré, Les gradients produisent des modifications qui s'ajoutent ou se retranchent de $\overrightarrow{B_0}$.Deux bobines établissent des gradients $\vec{G}_x$ et $\vec{G}_y$ perpendiculaires au champ $\overrightarrow{B_0}$, et un troisième système fournit un gradient $\overrightarrow{G_z}$ parallèle $\overrightarrow{B_0}$.les gradients les plus intense utilisé en imagerie sont de 10 milliteslas par mètre (mT/m).
- D'antennes : bobine de cuivre qui entoure le patient ou la partie du corps à explorer, elles permettent l'émission des ondes RF (émettrices) ou capter le signal (réceptrices)

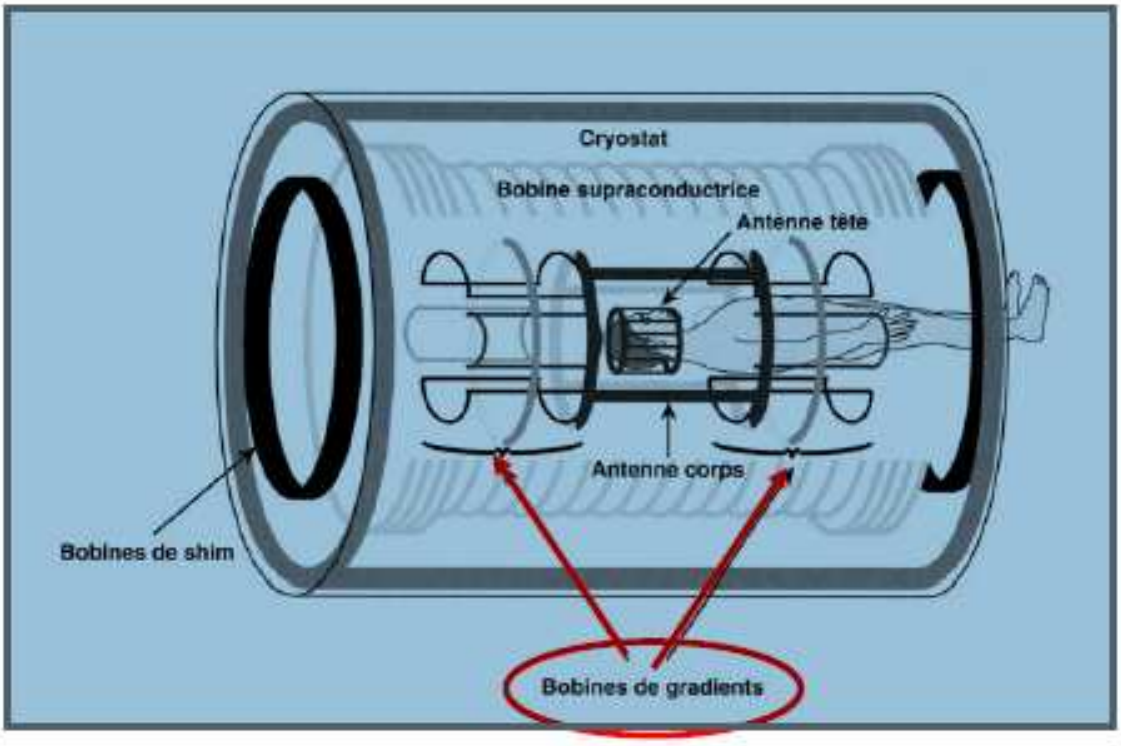

Figure.1.18. L'imageur IRM

1.8. Le produit de contraste en IRM

Deux produits de contraste existe à savoir : le produit de contraste T1 et le produit de contraste T2.

1.8.1. Le produit de contraste T1

Substance paramagnétique ; elle a des électrons célibataires qui induisent un champ magnétique local entrainant une diminution de T1 ce qui implique l'augmentation du contraste en T1, la plus utilisée est le gadolinium. L'injection de cette dernière présente un intérêt majeur dans le diagnostic des tumeurs cérébrales. En effet, sans ce produit de contraste, une image peut ne pas refléter la présence de la tumeur.

1 .8.2.Le produit de contraste T2

Substance superparamagnétique qui induit des hétérogénéités du champ magnétique accélérant les déphasages des protons et entrainant une diminution de T2 ce qui implique l'augmentation du contraste en T2.

1 .9. Incertitudes et imprécisions des images IRM

Les images IRM permettent une observation de qualité de l'anatomie cérébrale. En particulier, la résolution des images obtenues par cette technique est bien supérieure aux résolutions des images tomographiques (scanner). De plus, l'IRM, particulièrement sensible à de faibles modifications anatomiques, permet un suivi des tumeurs et de leur évolution. Cependant, comme toute image issue d'un système d'acquisition, les images IRM sont imparfaites.

L'incertitude et l'imprécision sont alors leurs deux principaux défauts qui sont dûs au système d'acquisition, au phénomène de dérive et à l'effet de volume partiel [9].

1.9.1. Le système d'acquisition

La première cause d'incertitudes et d'imprécisions est due au système d'acquisition. Dans l'univers du traiteur d'images, on retrouvera alors ces défauts sous la terminologie de bruit d'acquisition, il est assimilable à un bruit blanc.

Le bruit des images IRM se mesure grâce au rapport signal sur bruit (RSB). Ce dernier est lié au contraste et à la résolution de l'image.

En effet :

- ✓ l'intensité du signal est directement liée à l'intensité du champ magnétique B_0.
- ✓ le RSB diminue avec l'augmentation de la résolution des images.
- ✓ le RSB est proportionnel au nombre d'accumulations. Cependant, l'amélioration du RSB se fait au détriment du temps d'acquisition.

Un autre phénomène de bruit existe, Il s'agit du repliement de l'image (aliasing) qui apparaît lors de la reconstruction des images en cas de sous-échantillonnage du signal. Ce phénomène se traduit par un phénomène d'écho qui peut s'observer en particulier sur les coupes axiales supérieures (figure 1.19). Ce bruit contribue à augmenter l'incertitude sur les données.

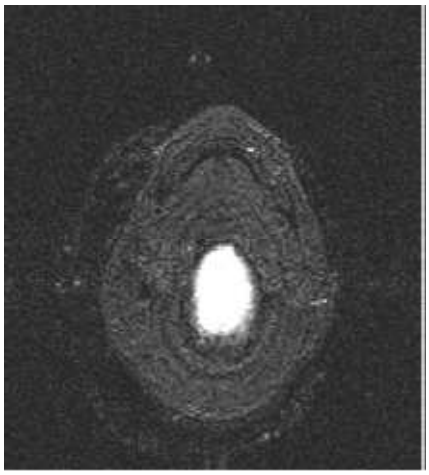

Figure.1.19. Phénomène de repliement du spectre

1.9.2. Phénomène de dérive

Le phénomène de dérive est une cause importante d'incertitudes. Ce phénomène se traduit sur les images par des variations importantes du niveau radiométrique moyen au sein d'une même structure. Sa principale origine est une dérive du champ radiofréquence des bobines lors de l'acquisition des images. Un moyen de lutte préventif est alors de régulièrement contrôler la qualité des acquisitions et de réaliser des étalonnages.

1.9.3. Effet de volume partiel

Parmi les causes d'imprécisions, nous pouvons citer l'effet de volume partiel. Cet effet est directement lié à la résolution des images. Lors d'une acquisition, il est fréquent qu'un voxel, image d'un volume élémentaire reconstruit, coupe une ou plusieurs zones anatomiques. Le voxel ne contient alors pas la représentation d'une structure unique mais au mélange de plusieurs structures. Les transitions entre régions sont progressives en termes de niveau radiométrique (figure 1.20) et les frontières entre les différentes régions apparaissent floues.

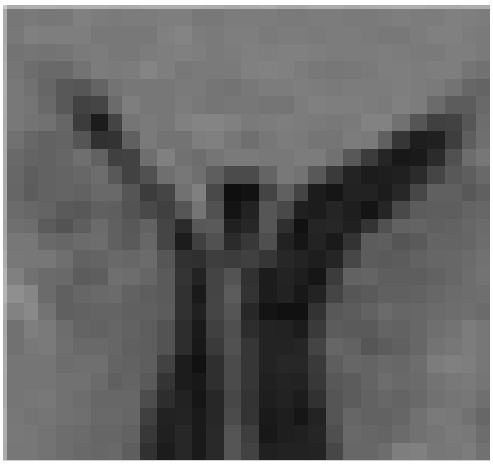

Figure.1.20. Effet de volume partiel

1.10. Discussion

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, et nous venons de voir que malgré la bonne résolution des images IRM, elles restent imparfaites, alors une segmentation précise et robuste du tissu cérébral donné par IRM s'impose pour la bonne séparation des tissus cérébraux et la bonne détection des tumeurs.

Dans le chapitre suivant nous exposons les différentes méthodes de segmentation d'image IRM.

Chapitre 2

Méthodes de segmentation d'images IRM

CHAPITRE 2

METHODES DE SEGMENTATION D'IMAGES IRM

2.1. Préambule

La segmentation d'image joue un rôle prépondérant dans le traitement d'image et dans la vision par ordinateur. Elle a pour but d'extraire à partir d'une image numérique des informations utiles qui pourront permettre de localiser et de délimiter les entités présentes dans l'image.

La segmentation précise et robuste du tissu cérébral donné par IRM est une question très importante dans beaucoup d'applications et en particulier, dans l'étude de certains tumeurs, l'analyse et l'estimation quantitative des processus de croissance de ces tumeurs et l'évaluation des effets de certains traitements médicamenteux en clinique [6].

Une segmentation du tissu cérébral consiste à séparer les différents tissus tumoraux, l'œdème et la nécrose, ainsi que les tissus normaux tels que la matière grise, la matière blanche et le liquide céphalo-rachidien [6].

Nous présentons ci après les principales méthodes de segmentation des images IRM.

2.2. Généralités sur la segmentation

Fondamentalement, la segmentation est un processus qui consiste à découper une image en régions connexes présentant une homogénéité selon un certain critère, comme par exemple la couleur. L'union de ces régions doit redonner l'image initiale .La segmentation est une étape importante pour l'extraction des informations qualitatives de l'image.

La segmentation est un traitement de bas niveau qui consiste à créer une partition de l'image observée en un certain nombre de régions qui pourront être par la suite traitées de manière différente.

Il n'ya pas de méthode unique de segmentation d'image, le choix d'une technique est liée à plusieurs facteurs, comme la nature de l'image (optique, infrarouge,…), les conditions d'acquisition (éclairage, présence de bruit,…) les primitives à extraire (contour, segments de droite, texture,…).du fait de cette diversité, il est difficile de définir, de manière absolue, une bonne segmentation.

2.3. Définition numérique de la segmentation d'images

La segmentation est un traitement qui consiste à créer une partition de l'image I en n sous ensembles R_i (i=1,2,…, n) de régions tels que :

1) $\bigcup_{i=1}^{n} R_i = I$

2) $Ri \cap Rj = \Phi$

3) Les sous ensembles R_i, i=1,…, *n* sont connexes

4) Il existe un prédicat *P* tel que : $P(R_i)$ = *vrai*, ∀ i=1,…, n

5) $P(R_i \cup R_j)$ = *faux*, ∀(i,j), $i \neq j$ et R_i et R_j sont contiguës.

Le premier et le deuxième point signifient que **I** est partitionné en n sous ensembles disjoints deux à deux.

Le troisième, le quatrième et le cinquième point imposent à chaque pixel d'une région, de satisfaire à la même propriété au sens du prédicat **P**. le prédicat **P** n'est plus vrai pour la réunion de deux région adjacentes.

Le prédicat à la base de la définition des régions doit être choisi à travers des descripteurs de pixels susceptibles de permettre une bonne identification des objets. Parmi ceux-ci, on peut citer : Le niveau de gris, la couleur, la texture, la géométrie,…Il faut cependant noter que dans plusieurs cas, l'addition de bruit par la numérisation ou par l'environnement, font que la segmentation d'une scène n'est possible que si plusieurs attributs sont utilisés simultanément [11] [12] [34].

2.4. Méthodes de segmentation d'images

La segmentation fait référence aux notions de différence et de similarités perçues par le système visuel humain. Ceci donne naissance à deux approches principales couramment qualifiées d'approche frontière et d'approche région. L'approche région s'attache à faire apparaitre des régions homogènes selon un critère (niveaux de gris ou texture), alors que l'approche frontière tente de trouver des contours ou frontières de régions présentant une variation rapide du même critère.

Un algorithme de segmentation s'appuie sur les trois points essentiels suivants :

- La recherche de discontinuités afin de mettre en évidence les contours.
- La recherche d'homogénéité locale pour définir les régions.
- Ou encore sur la coopération des deux principes.

De nombreuses méthodes ont été publiées dans la littérature [11][12][13].Cependant le choix d'une technique reste un problème posé et dépend fortement de l'application envisagée ainsi que du type d'images à traiter. Nous décrivons ci après les principales approche à savoir : l'approche région et l'approche frontière.

2.4.1. Approches régions

Les méthodes de segmentation par approche région sont nombreuses. Elles consistent à rechercher des ensembles de pixels qui possèdent des propriétés communes.

Les parties connexes de ces ensembles constituent les régions. Le choix des propriétés étudiées est déterminé par le (ou les) critère(s) de segmentation. L'homogénéité d'une région peut être définie de plusieurs façons : niveaux de gris, couleur, texture etc… [11], [12].

L’approche région peut être classée en plusieurs catégories, à savoir :

Les méthodes de classification, les méthodes de type croissance de région et les méthodes basées sur l’analyse de texture.

2.4.1.1. Les méthodes de classification

Les classes sont construites à partir des attributs des pixels. Chaque pixel est affecté à une classe unique. Parmi les méthodes de classification les plus classiques en segmentation région, on retrouve la technique K-means [14].

Cette méthode de classification présente un problème du choix du nombre de classes et un problème du choix des attributs.

2.4.1.2. Les méthodes de type croissance de région

La segmentation par croissance de région commence d’abord par choisir des germes de régions, puis faire croitre chaque germe en intégrant progressivement des pixels voisins à ces germes [9].

Les méthodes fondées sur la croissance de régions permettent aussi bien la segmentation de structures saines [15] [16] que la segmentation de structures pathologiques [17] [18]. Elles sont simples à mettre en œuvre, mais parfois coûteuses en temps de calcul. Leurs avantages résident dans la prise en compte des informations contextuelles par le mécanisme de croissance. Néanmoins, leurs inconvénients sont liés à la disposition des germes initiaux. En effet, celle-ci nécessite l’intervention d’un opérateur, en particulier lorsqu’il s’agit de détecter des tumeurs, qui, n’ont pas de localisation à priori dans le cerveau, et sur lesquelles nous ne disposons d’aucune connaissance anatomique.

2.4.2. Méthodes basées sur l’analyse de texture

La texture est une des propriétés de base de l’image. Elle représente l’ordonnancement visuel du changement des niveaux de gris dans une surface de l’espace ou une structure d’un objet. La caractérisation d’une texture repose sur des attributs tels que le contraste, la structure

des lignes, la régularité et la rugosité,… etc. Son but principal est l'identification de texture et l'analyse de forme basée sur celle-ci [19] [20].

L'image IRM du cerveau présente des zones de textures très complexes. Il n'est pas facile de trouver des modèles de texture qui peuvent séparer tissus normaux et anormaux tels que les tumeurs. Ainsi l'application de l'analyse de texture n'est pas satisfaisante pour la segmentation de tumeurs du cerveau en imagerie IRM.

2.4.3. Approche frontières

Cette approche est une technique non contextuelle, qui ignore les relations pouvant exister entres les régions de l'image.

Les pixels sont regroupés en fonction d'un attribut global. Elle comprend les techniques de détection de contours. Cependant, les contours obtenus ne conduisent pas, toujours, directement à la partition recherchée. En effet, les pixels contours mis en évidence pour une forme, généralement, ne sont pas connexes. Il faut alors appliquer les algorithmes de fermetures de contours [21]. Ce n'est qu'après fermeture des contours que les régions apparaissent, définies par l'intérieur des contours.

2.4.3.1. Approche contours

Un contour est une brusque variation de niveau de gris dans une image, il est aussi défini comme la frontière entre deux régions dissemblables dans une image. les contours sont, aussi, les variations significatives de l'information.

Il existe une grande variété de contours d'une image, ces derniers renferment une information très riche sous forme très condensée. Un contour peut être défini comme une "marche d'escalier" si le contour est net, comme une "rampe" si le contour est plus flou ou comme un "toit" s'il s'agit d'une ligne sur un fond uniforme (fig2.1).

(a) **(b)** **(c)**

Figure.2.1 : différent model de contours

(a) Marche : le contour est net (contour idéal).
(b) le contour est plus flou.

(c) Toit : il s'agit d'une ligne sur un fond uniforme.

L'extraction de contours a pour but d'identifier les caractéristiques significatives de l'image. Elle se base sur la distribution des niveaux de gris des pixels. Le principe de cette méthode est, essentiellement, d'effacer tous les motifs à faible variation de niveaux de gris(ou de couleur) pour ne conserver que les lignes de séparation entre région homogènes.

Pour cela, différentes approches sont utilisées tel que les contours actifs et les approches dérivatives.

a. Les contours actifs

Un contour actif est un ensemble de point qu'on va tenter de déplacer, pour leur épouser une forme. L'idée de cette méthode est de déplacer les points pour les approcher des zones de fort gradient, tout en conservant des caractéristiques comme la courbure du contour ou la répartition des points sur le contour [13].

La segmentation par l'approche contour actif s'avère efficace pour la segmentation de structures anatomiques particulières. Elle permet en effet de s'adapter à la forme complexe des structures grâce à l'enrichissement des contraintes de déformation. Cependant, cette approche reste relativement sensible à l'initialisation de la courbe de départ.

b. Les approches dérivatives

Les approches dérivatives regroupent les différents opérateurs basés sur le calcul du gradient, les filtres optimaux et le laplacien.

b.1. Approche gradient

Le gradient en un pixel d'une image numérique est un vecteur caractérisé par son amplitude et sa direction. L'amplitude est directement liée à la quantité de variation locale des niveaux de gris. La direction du gradient est orthogonale à la frontière qui passe au point considéré [22].

Dans une image supposée continue f(x, y), un contour apparaît comme une ligne où sont localisées les très fortes variations de f.

Soit $\overrightarrow{G}$ le gradient de f

$$\overrightarrow{G} = \overrightarrow{\nabla f} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (2.1)$$

On associe à une image le module du gradient de f :

$$G = \left|\overrightarrow{\nabla f}\right| = \left[\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2\right]^{1/2} \quad (2.2)$$

$$G(x, y) = \sqrt{G_x(x,y)^2 + G_y(x,y)^2} \quad (2.3)$$

Et la direction du gradient qui est donnée par :

$$D(x,y) = \arctan\left(\frac{G_y}{G_x}\right) \quad (2.4)$$

Le calcul des dérivées peut être réalisé par différentes méthodes soit par le calcul direct ou par différents masques.

b.1.1. Calcul direct

On peut calculer G(*x, y*) en convoluant directement avec deux filtres (voir figure.2.2) :

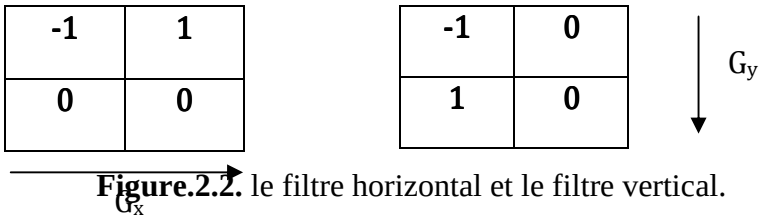

Figure.2.2. le filtre horizontal et le filtre vertical.

b.1.2. Operateur de Robert

L'operateur de Robert permet de calculer le gradient bidimensionnel, d'une image, de manière simple et rapide. Il amplifie les zones où le gradient spatial est important, qui correspond souvent au contour. Mais il est très sensible aux bruits [22].
Les masques de Robert sont les suivants :

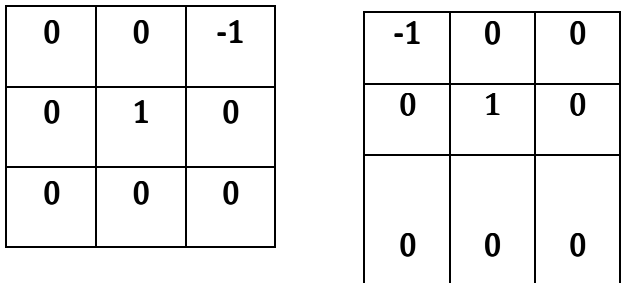

Figure.2.3. Operateur de Robert

Sur la figure ci-dessous, nous donnons un exemple d'image IRM d'un cerveau sain après lui avoir appliqué l'opérateur de Roberts.

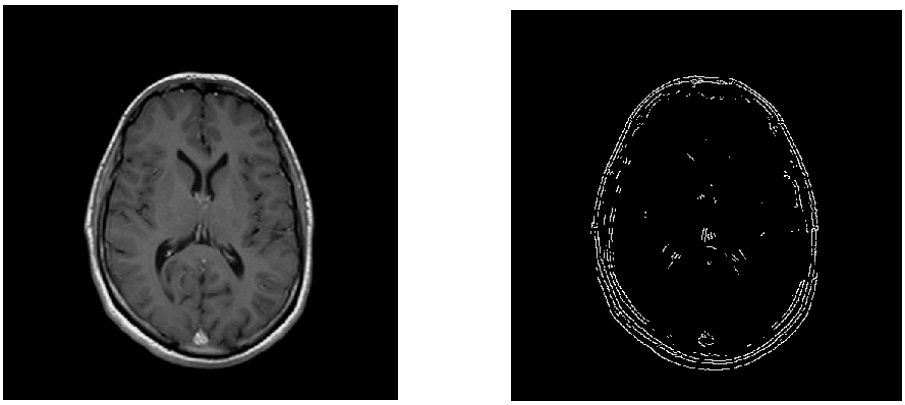

Figure.2.4. A gauche une image IRM d'un cerveau sain.

A droit une image de contour de Robert.

b.1.3. Opérateur de Sobel

Pour cet operateur, nous utilisons les 2 masques suivants, pour calculer le gradient (fig2.5) :

-1	**0**	**1**
-2	**0**	**2**
-1	**0**	**1**

Filtre vertical

-1	**-2**	**-1**
0	**0**	**0**
1	**2**	**1**

filtre horizontal

Figure.2.5. les opérateurs de Sobel (horizontal et vertical)

Pour illustrer le résultat de cette opération, nous donnons un exemple sur la figure (2.6)

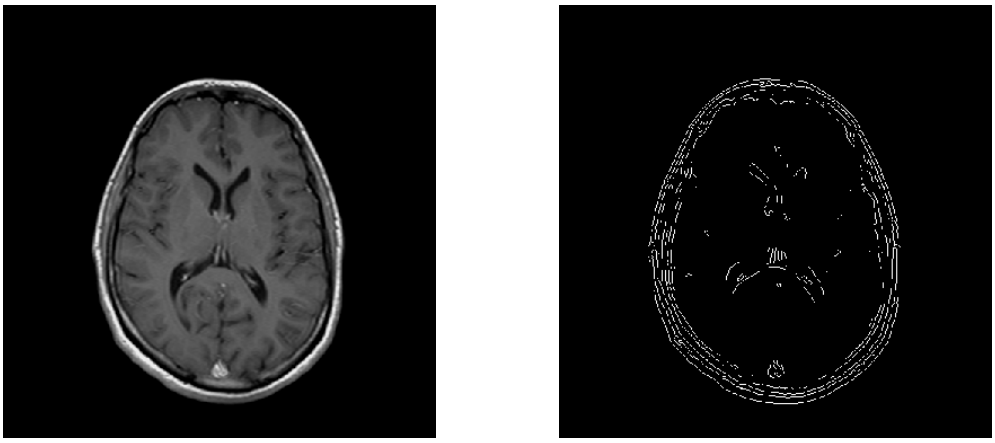

Figure.2.6. l'image contour après avoir appliqué l'opérateur de Sobel

b.1.4. Opérateur de Prewitt

L'opérateur de Prewitt combine à la fois un filtrage et une dérivée. Il est donc moins sensible aux bruits que le calcul direct des dérivées. fig2.7

-1	-1	-1
0	0	0
1	1	1

1	0	-1
1	0	-1
1	0	-1

Figure.2.7. les Opérateur de Prewitt

Le résultat de ce masque sur une image IRM d'un cerveau sain est illustré sur la figure (2.8).

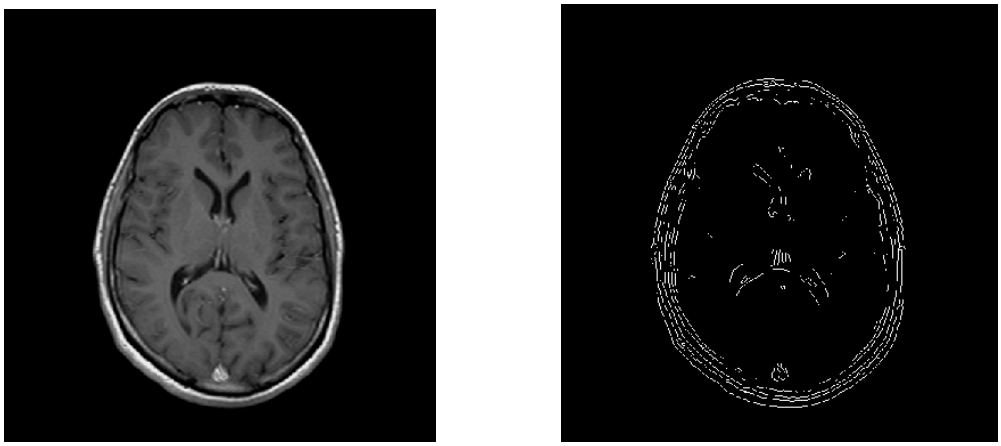

Figure.2.8. A gauche une image IRM du cerveau sain.

A droit une image de contour de Prewitt.

b.1.5. L'approche Laplacien

Le laplacien est un opérateur de dérivée seconde, il permet de détecter les brusques variations d'intensité dans les images en sélectionnant les points dont la dérivée première présente une brusque variation d'intensité. Il permet de réduire les erreurs de fausses alarmes en rejetant les gradients de faible intensité. Les points de contours qui correspondent à un maximum local, correspondent à des passages par zéro pour la dérivée seconde.

Celui-ci peut être estimé à une convolution avec les masques représentés sur la Figure.2.9.

0	**1**	**0**
1	**-4**	**1**
0	**1**	**0**

-1	**-1**	**-1**
-1	**8**	**-1**
-1	**-1**	**-1**

1	**-2**	**1**
-2	**1**	**-2**
1	**-2**	**1**

Figure.2.9. les déférents masques de Laplacien

L’inconvénient des méthodes dérivatives est lié à leur forte sensibilité au bruit et aux contours mal définis

c. L’approche de Canny

La détection de Canny repose sur une dérivée première d’une gaussienne. Un contour est détecté lorsque le module du gradient est maximal dans la direction du gradient. De plus, avant de calculer le gradient, il est nécessaire de lisser l’image par un noyau de convolution pour réduire le bruit. Ce noyau de convolution est la dérivée d’une gaussienne. L’approche de canny garantit : La bonne détection, la bonne localisation et une réponse unique [23].

Canny a supposé que la détection a été effectuée par convolution de l’image I(x) avec une fonction f(x) et le contour c'est le maximum du sortie Θ(x), il est donné par l’équation (2.5).

$$\Theta(x_0)=\int_{-\infty}^{+\infty} I(x)f(x_0-x)dx \qquad (2.5)$$

c.1. Bonne détection

Garantir une bonne détection c’est de garantir une réponse forte même à de faibles contours. Le filtrage *f*(x) doit avoir une réponse plus forte que le bruit au contour x = 0, pour cette raison le rapport signal sur bruit (RSB) qui est défini par [24]:

$$\text{RSB}=\frac{A}{n_0}\cdot\frac{\left|\int_{-\infty}^{0} f(x)dx\right|}{\left[\int_{-\infty}^{+\infty} f^2(x)dx\right]^{\frac{1}{2}}} \qquad (2.6)$$

Doit être maximal.

c .2. Bonne localisation

Le filtrage f(x) doit avoir une réponse maximale. Ce critère concerne la localisation des points détectés, pour minimiser la distance entre le contour détecté et le vrai contour.
La localisation [24] L est définie par l’équation (2.7):

$$L=\frac{A}{n_0}\cdot\frac{|f'(0)|}{\left[\int_{-\infty}^{+\infty}f'^2(x)dx\right]^{\frac{1}{2}}} \qquad (2.7)$$

c.3. Réponse unique

Il faut avoir seulement un maximum dans les voisins du point x=0. Le détecteur ne doit pas fournir de multiples réponses à un seul contour.

La distance moyenne [24] entre les maximaux locaux est définie :

$$x_{max}=2\cdot\pi\cdot\left[\frac{\int_{-\infty}^{+\infty}f'^2(x)dx}{\int_{-\infty}^{+\infty}f''^2(x)dx}\right]^{\frac{1}{2}} \qquad (2.8)$$

La fonction f(x) adaptée par canny est la fonction première dérivative du Gaussien [24]

$$f(x)=-\frac{x}{\sigma^2}e^{\frac{x^2}{2}\sigma^2} \qquad (2.9)$$

c.4. L'algorithme de détection de contour basé sur l'approche de Canny

L'algorithme de détection de contour par l'approche de Canny est basé sur les étapes suivantes [24] [25][26] :

- Lissage de l'image à l'aide d'un filtre gaussien.
- Calcul du module et l'orientation du gradient pour chaque pixel.
- Suppression du non-maxima pour le module du gradient.
- Utilisation de l'algorithme de double seuil pour détecter et lier les arêtes.

c.4.1. Le filtrage Gaussien

La fonction gaussienne [17] a la forme:

$$G(x,y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\pi\sigma^2}} \qquad (2.10)$$

Approximation discrète à la fonction gaussien et sa distribution avec $\boldsymbol{\sigma = 1.}$

L'opérateur lissé gaussien peut être effectué en utilisant des méthodes standards [21] de convolution.

Dans le cas continue :

$$I_{gass}(x,y) = I(x,y) * G(x,y) = \int_{\infty} \int_{\infty} I(u,v).G(u-x, v-y)dudv \qquad (2.11)$$

Dans le cas discret :

$$I_{gauss}(x,y) = G * I(m,n) = \sum_{i'=-k/2}^{i'=+k/2} \sum_{i'=2}^{i'=+k/2} G(i',j') * I(m-i', n-j') \qquad (2.12)$$

Avec K: taille du masque gaussien

c.4.2. Déterminer la magnitude du gradient et la direction du gradient

Après avoir lissé l'image et éliminer le bruit, l'étape suivante [27] [28] [29] est de calculer la magnitude du gradient et la direction du gradient.

$$G(m, n) = \sqrt{G_x(x,y)^2 + G_y(x,y)^2} \qquad (2.13)$$

$$\theta(m,n) = \arctan\left(\frac{G_y}{G_x}\right) \qquad (2.14)$$

c.4.3. Suppression de non-maxima

Pour identifier les contours, il faut combiner les pixels dans l'image d'amplitude du gradient à un seul pixel. Pour le faire, seulement des pixels qui ont de plus grandes variations locales (maxima locaux) sont choisis pour déterminer les contours. La sélection des maxima locaux dépend de l'orientation du gradient. Les différents angles sont illustrés par la figure.2.10.

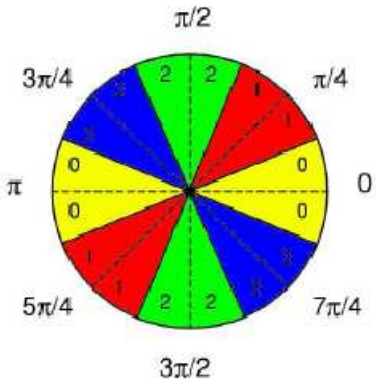

Figure.2.10. Les différents angles du gradient

d(m,n)=Secteur(θ(m,n))

Secteur 0= [-π/8, π/8] et [7π/8,9π8]

Secteur 1= [π/8,3π/8] et [9π/8,11π8]

Secteur 2= [3π/8,5π/8] et [11π/8,13π8]

Secteur 3= [5π/8,7π/8] et [13π/8,15π8]

Pour chaque point de l'image Gradient G(m,n), nous le comparons avec ses deux voisinage le long de d(m,n) , G(m,n) est supprimé s'il est le plus petit que ses deux voisinage

La dernière étape, c'est de réduire les faux contours. Pour le faire, des techniques de seuillage sont appliquées (Seuillage Classique, Seuillage par hystérésis).

Avec le détecteur de canny, nous obtenons des contours à une seule échelle, et ce n'est pas suffisant pour la segmentation des images IRM car il n'est pas flexible (une seule réponse par contour), nous allons donc utiliser les ondelettes pour pallier à ce problème. La caractéristique de la transformée par ondelettes est d'ajouter les échelles comme paramètre de détection.

2.5. Discussion

Nous venons de décrire quelques approches de segmentation d'images. La diversité de ces méthodes est due à la multitude des caractéristiques des problèmes à considérer.

Il n'y a pas de règles générales permettant de choisir une méthode particulière de segmentation pour un problème donné. Choisir l'une ou l'autre méthode dépend des images à segmenter. Chacune de ces méthodes a des avantages et des inconvénients.

Le contexte de notre étude repose plus particulièrement sur l'aide au diagnostic des tumeurs cérébrales. L'objectif visé est de détecter précisément la zone tumorale, c'est-à-dire de l'isoler des principales structures cérébrales. Notre problématique est donc de segmenter les tumeurs cérébrales à partir des images IRM. Cette segmentation doit naturellement être reproductible, précise et fiable. Pour cette raison nous avons choisi le détecteur multi-échelle de canny.

Dans le prochain chapitre, nous présenterons le détecteur multi échelle de canny .

Chapitre 3

Segmentation d’images par le détecteur multi échelles de canny

CHAPITRE 3

SEGMENTATION D'IMAGES PAR LE DETECTEUR MULTI ECHELLES DE CANNY

3.1. Préambule

L'analyse multi-échelle consiste à décomposer l'image sur une gamme très étendue d'échelles, opération que nous pouvons comparer à une cartographie. A chaque échelle, l'image est remplacée par l'approximation la plus adéquate que l'on puisse y tracer. En allant des échelles les plus grossières vers les plus fines, nous accédons à des représentations de plus en plus précises de l'image donnée. L'analyse s'effectue en calculant ce qui diffère d'une échelle à l'autre, c'est à dire les détails à une résolution donnée.

L'imagerie médicale permet d'analyser les tissus par des médias extrêmement divers, leurs exploitations et leurs interprétations permettent d'établir plus finement le diagnostic médical. Comme nous l'avons montré au chapitre précédent l'outil le plus adapté aux images IRM est le détecteur multi-échelles de Canny [46]. Ce dernier combine les propriétés du détecteur de contour de canny et les transformées en ondelettes (forts coefficients sur les points de contour).

L'algorithme du détecteur multi-échelles de Canny repose sur la décomposition par convolution en cascade B-spline que nous présentons et justifions dans ce chapitre après avoir rappelé succinctement la transformée de fourrier, la théorie des ondelettes et leur relation avec le détecteur de canny.

3.2. La transformée de Fourier

L'analyse spectrale et la décomposition du signal ont toujours leur place dans l'analyse des données dans le domaine du traitement du signal. L'idée de base de la décomposition est de représenter le signal par ces différentes composantes spectrales afin qu'il soit possible de décomposer et de reconstituer le signal initial à partir de ces composantes. La transformation, intermédiaire, entre le domaine temporel et fréquentiel est celle de Fourier [30] [31]. Elle permet la décomposition en une série ou une intégrale de Fourier défini par :

$$\hat{f}(\omega)=\int_{-\infty}^{+\infty} f(x)\, e^{-i\omega x} dx \qquad (3.1)$$

Cette transformation permet de décrire la répartition des composantes fréquentielles du signal f(x) sans nous renseigner sur les endroits de l'apparition de celles-ci.

Les renseignements fréquentiels ainsi obtenus le sont au détriment de la description spatiale explicite du signal.

Cette méthode ne convient donc pas à tous les types de signaux, notamment des signaux non stationnaires. Elle est aussi insuffisante pour mettre en évidence les caractéristiques évolutives du signal. Pour pallier ces problèmes, d'autre approche qui prennent en compte le paramètre temporel ont été développé. Une solution partielle fut alors d'associer à un signal non stationnaire une suite de TF à court terme en essayant d'adapter les fenêtres d'observation successives aux variations de structure du signal afin que la localisation soit satisfaite. Nous pouvons donner pour exemple la transformée de Fourier Glissante (TFG).

La TFG consiste à associer une suite de transformations de Fourier sur de petits intervalles de temps, en appliquant « une fenêtre spatiale glissante » (figure 3.1) dans l'intégrale de Fourier, la fenêtre est translatée sur tout le domaine spatial du signal. C'est une transformation de Fourier qui est localisée dans le voisinage de τ grâce à une fenêtre ; ainsi les mesures se feront au tour du point τ.

$$\hat{f}(\omega,\tau)=\int_{-\infty}^{+\infty} f(x).g(x-\tau).e^{-i\omega x}dx \qquad (3.2)$$

Où :

f(x) : Signal à traiter.

τ : Translation de la fenêtre.

$g(x-\tau)$: Représente une fenêtre en déplacement sur tout le domaine de définition du signal à analyser.

ω : Notation de pulsation.

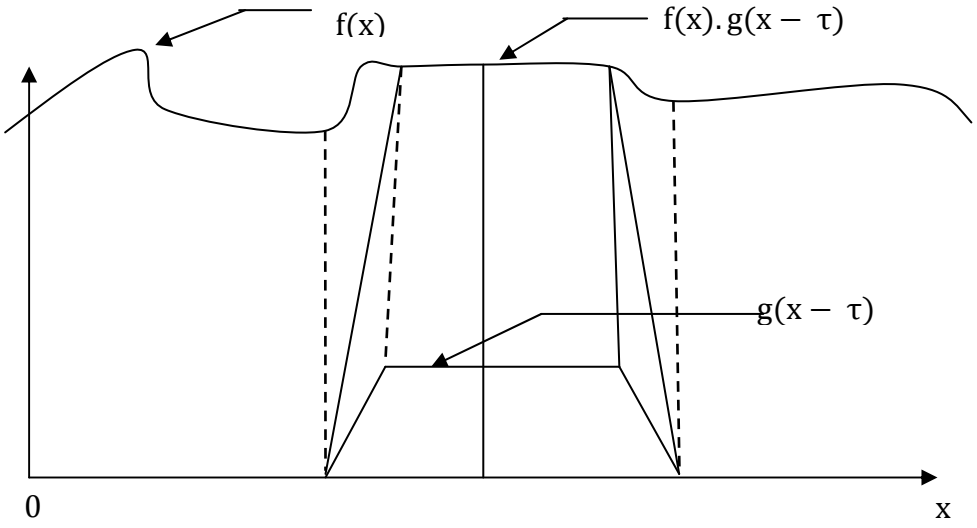

Figure.3.1. Influence de la fenêtre glissante sur le calcul de la TF

Cette solution se heurte, malheureusement à une limitation de la résolution temporelle due à la taille fixe de l'enveloppe de la fenêtre ; fixer la taille de l'enveloppe fixe en conséquence la résolution dans cette représentation temps-fréquence.

A l'inverse de la TF, la transformée en ondelettes est conçue pour être adaptative : elle consiste à analyser le signal f à l'aide d'une fonction bien localisée Ψ de moyenne nulle, qu'on appelle ondelette, que l'on translate et on dilate sur tout le signal.

3.3. Eléments de la théorie des Ondelettes

3.3.1. Définition des ondelettes

Les ondelettes sont une famille de fonctions engendrées par translation en temps et dilatation en fréquence à partir d'une même fonction ψ, appelé ondelette mère [32] [33] [35] [36]. Elles sont normalisées suivant l'équation (3.3)

Elles ont pour expression générale la forme suivante :

$$\psi_{a,x}(t) = \frac{1}{\sqrt{a}}\psi\left(\frac{t-x}{a}\right) \qquad (3.3)$$

Où $\psi(t)$ est une fonction bien localisée en temps et en fréquence.

« a » : paramètre de dilatation (paramètre d'échelle).

«**x »** : paramètre de translation.

L'ondelette analysante doit cependant satisfaire à des conditions mathématiques d'admissibilité de telle sorte que l'énergie soit conservée et que le signal d'analyse puisse être reconstruit. Pour ce faire, cette dernière doit être oscillante et à moyenne nulle [37] [38] [39].

Il existe différents types de famille d'ondelettes.

- On peut faire varier les paramètres a et x dans R^* x R (domaine continu) ; on parle alors de la transformation en ondelette continue.

- On peut faire varier les paramètres a et x dans un domaine discret ; dans ce cas on parle de la transformation en ondelette discrète.

3.3.2. Transformation en ondelette continue(TOC)

En faisant varier les paramètres a et x dans un domaine continu, nous obtenons une transformation en ondelette continue.

La transformée ondelette d'une fonction f ∈ L^2 (R) consiste en une projection de celle-ci sur la famille d'ondelette choisie, on peut alors représenter cette fonction par la fonction *CWT(f).*

$$CWT(a,x) = \langle \psi_{a,x}, f \rangle = |a|^{-1/2} \int_{-\infty}^{+\infty} \bar{\psi}\left(\frac{(t-x)}{a}\right).f(t)dt \qquad (3.4)$$

Avec $\bar{\psi}$: complexe conjugué de ψ

3.3.3. Ondelettes 2D directionnelle

Pour avoir une ondelette à 2D il faut varier les variables d'intégration et le paramètre de translation x dans R^2 et non plus dans R [40] [45].
Une ondelette est une fonction $\psi \in L^2$ (R) qui vérifie la condition d'admissibilité suivante :

$$c_\psi = \iint_{R^2} \frac{|\hat{\psi}(\vec{k})|^2}{\|\vec{k}\|^2} d\vec{k} < \infty \qquad (3.5)$$

Dans une image, les contours peuvent être orientés selon toutes les directions ; le long d'une arête, l'image parait assez régulière (sauf si elle traverse une autre arête).

Alors en 2D Pour obtenir des informations dans une direction donnée, il faut faire intervenir un troisième paramètre, un angle $\theta \in [0,2\pi]$. On définit ainsi la transformée en ondelettes directionnelle.

Soit ψ une Ondelette 2D. La transformée en Ondelettes directionnelle [41] d'une fonction $f \in L^2(R^2)$ est définie, pour $x \in R^2, a > 0,\ \theta \in [0,2\pi]$ par :

$$wf(\vec{x},a,\theta) = \iint_{R^2} f(\vec{t}) \frac{1}{a} \overline{\psi(R^{-\theta} \frac{\vec{t}-\vec{x}}{a})}\, d\vec{t} \qquad (3.6)$$

Où R^{θ} : désigne la matrice de rotation

$$R^{\theta} = \begin{pmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{pmatrix} \quad (3.7)$$

3.3.4. Discrétisation

Les formules rappelées plus haut sont continues et ne peuvent pas être implémentées comme telles, il faut les discrétiser [42]. Le principe est de prendre un ensemble discret $\{a_n\}_{n=1\ldots n_{ma}}$ d'échelles, et pour chaque échelle a_n de prendre un ensemble discret de paramètres de translation $\{(x_n^i, y_n^j\}_{i=1\ldots with, j=1\ldots Reight}$ couvrant tout le domaine de définition de l'image.

Nous pouvons discrétiser la transformée en ondelettes en échantillonnant les échelles « *a* » et les paramètres de translation « *x* » de manière régulière :

$$a_n = a_0 n \quad (3.8)$$

Avec : n = 1…….a_{max}

Les propriétés de la transformée en ondelettes continue sont alors conservées, en particulier l'invariance par translation.

Comme nous pouvons discrétiser la transformée en ondelettes en échantillonnant les échelles en choisissant :

$$a = a_0^n \quad (3.9)$$

Avec : $a_0 > 1$

On parcourt ainsi les fréquences du signal beaucoup plus rapidement, tout en restant précis sur les hautes fréquences (les petites échelles).

Le choix le plus populaire est de prendre $a_0 = 2$: les échelles sont discrétisées sur des valeurs dyadiques. Cette méthode est obtenue en prenant la formule de la transformée en ondelettes continue d'une fonction $f \in L^2(R)$ et en discrétisant le paramètre d'échelle selon les valeurs $(2^j)_{j\in z}$, elle donnée par l'équation (3.10) :

$$\forall j \in Z, \forall x \in R,\ Df(x, 2^j) = \int_{-\infty}^{+\infty} f(t)\ 2^{-\frac{j}{2}} \psi\left(\frac{t-x}{2^j}\right) dt \qquad (3.10)$$

3.4. Analyse Multi résolution (AMR)

Le concept de la multi résolution est d'utiliser plusieurs fois la transformation en ondelette afin de décomposer le signal de départ en plusieurs signaux contenant des informations différentes. D'une manière très simpliste, à la première échelle la DWT va extraire les détails les plus fins du signal. A la deuxième échelle, on aura les détails un peu plus grossiers et ainsi de suite, jusqu'à obtenir un signal complètement lisse [35] [36].

Une analyse multirésolution de $L^2(R)$ consiste en une suite de sous espaces fermées emboîtées $\overline{(V_j)_{j=-\infty \ldots +\infty}}$ qui vérifient les propriétés suivantes :

$$\forall j \in Z, V_j \in V_{j+1} \qquad (3.11)$$

$$\forall j \in Z, f(t) \in V_j \Leftrightarrow f(2t) \in V_{j+1} \qquad (3.12)$$

$$\forall j \in Z, f(t) \in V_0 \Leftrightarrow f(t-k) \in V_0 \qquad (3.13)$$

$$\lim_{j \to -\infty} V_j = \bigcap_{j=-\infty}^{+\infty} V_j = \{0\} \qquad (3.14)$$

$$\lim_{j \to +\infty} V_j = \overline{\bigcup_{j=-\infty}^{+\infty} V_j} = L^2(R) \qquad (3.15)$$

$\boldsymbol{j}$ s'appelle la résolution et représente le niveau d'analyse de la fonction $\boldsymbol{f}$; l'approximation dans $\boldsymbol{V_j}$ de $\boldsymbol{f}$ est deux fois plus fine que celle dans $\mathbf{V_{j-1}}$, mais deux fois moins bonne que celle dans $\boldsymbol{V_{j+1}}$ [42] [43].

Pour le cas des signaux 2D, Mallat a introduit un algorithme généralisant l'algorithme de décomposition à des images (figure.3.2). Il suffit de séparer la double dimension en deux dimensions simples : on filtre d'abord les lignes par un filtre passe-haut h, puis par un filtre passe-bas g. Ensuite, on filtre les colonnes des résultats obtenus par h, puis par g. On obtient alors quatre images dont la quatrième (colonnes et lignes filtrées par h) représente l'image de résolution moindre depuis laquelle on relance l'algorithme jusqu'au niveau désiré [30].

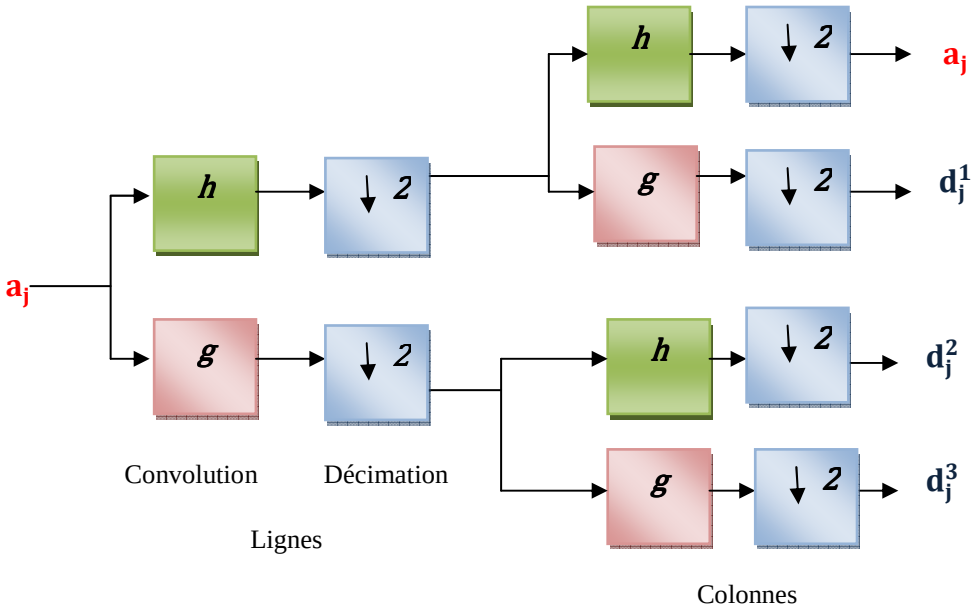

Figure.3.2. Algorithme de décomposition de l'image a_j par la transformée en ondelettes où g et h désignent respectivement un filtre passe-bas et un filtre passe-haut.

3.5. Algorithme à trous

Toutefois, cette décomposition en ondelettes par l'algorithme de Mallat, qui est utilisé principalement pour la compression d'images, ne convient pas à la segmentation en contours. En effet, le passage d'une échelle d'étude à l'autre par décimation du signal par un facteur 2 se traduit en deux dimensions par la suppression d'un pixel sur deux à la fois selon les lignes et selon les colonnes. Cependant la suppression d'un pixel sur deux, impose que la décomposition que l'on obtiendra ne sera pas invariante par translation, ce qui influe

énormément sur la qualité de l'image segmentée. Pour remédier à ce problème, il existe une autre méthode de décomposition appelé « algorithme à trous » (figure.3.3). L'utilisation de l'algorithme à trous crée une redondance d'information qui permet de maintenir l'invariance en translation à tous les niveaux de décomposition. De plus, il permet une bonne localisation spatiale des fréquences les plus basses [36] [43] [44].

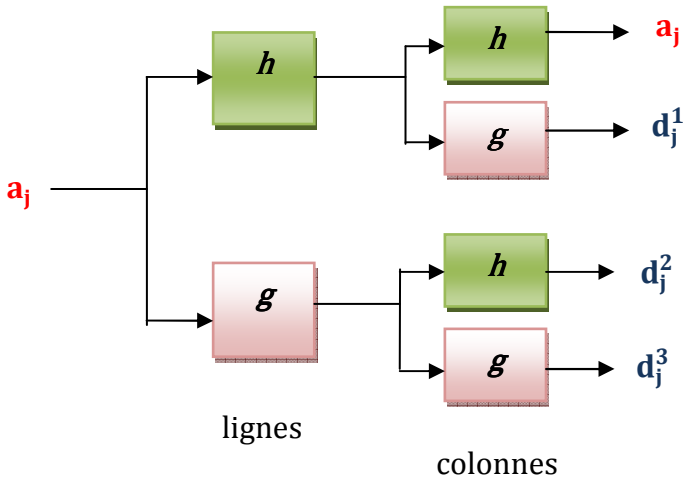

Figure. 3.3. Algorithme de décomposition de l'image a_j par la transformée en ondelettes redondante.

L'utilisation dyadique du détecteur multi-échelles, que l'on peut programmer à l'aide de l'algorithme à trous, est avantageuse parce qu'elle permet de calculer efficacement les coefficients d'ondelettes de l'image sur une large gamme d'échelles. Elle permet d'obtenir, après n étapes, les coefficients d'ondelettes, Cette transformée couvre bien le plan espace-fréquence.

Cependant, cette approche présente d'importants inconvénients : en particulier, à cause du sur échantillonnage, les maxima d'ondelettes crées par des points de contours vont très vite se diffuser à travers les échelles : il sera donc très difficile de définir un chainage entre tous les maxima d'ondelettes crées par un même point de contour, et il analyse l'image sur des échelles en 2^j qui sont très éloignées les unes des autres. Au contraire de l'approche dyadique, l'algorithme cascade B-spline, analyse l'image sur des échelles « a » variant entre 0 et a_{max} qui restent assez fines et qui sont proches les unes des autres.

La transformée en ondelette considérée ici n'est pas sous échantillonnée et elle est définie pour toute valeur positive du paramètre d'échelle.

3.6. Algorithme par convolution en cascade B-spline

L'algorithme par convolution en cascade B-spline peut être interprété comme un banc de filtrage dont les filtres passe-haut sont les filtres de dérivation Dx et Dy, et le filtre passe-bas le masque B-splineθ [45] (voir figure.3.4).

A chaque étape, la composante basse-fréquence

$$f * \overbrace{\theta * \theta * \dots\dots\dots\dots * \theta}^{n-1\ convolutions} \tag{3.16}$$

est convoluée d'une part par le filtre passe-basθ :

$$f * \overbrace{\theta * \theta * \dots\dots\dots\dots * \theta}^{n\ convolutions} \tag{3.17}$$

D'autre part par un filtre passe-haut de dérivation horizontale Dx :

$$w^1 f(x,y,n) = f * \overbrace{\theta * \theta * \dots\dots\dots\dots * \theta}^{n-1\ convolutions} * Dx \tag{3.18}$$

Et enfin par un filtre de dérivation verticale Dy :

$$w^2 f(x,y,n) = f * \overbrace{\theta * \theta * \dots\dots\dots\dots * \theta}^{n-1\ convolutions} * Dy \tag{3.19}$$

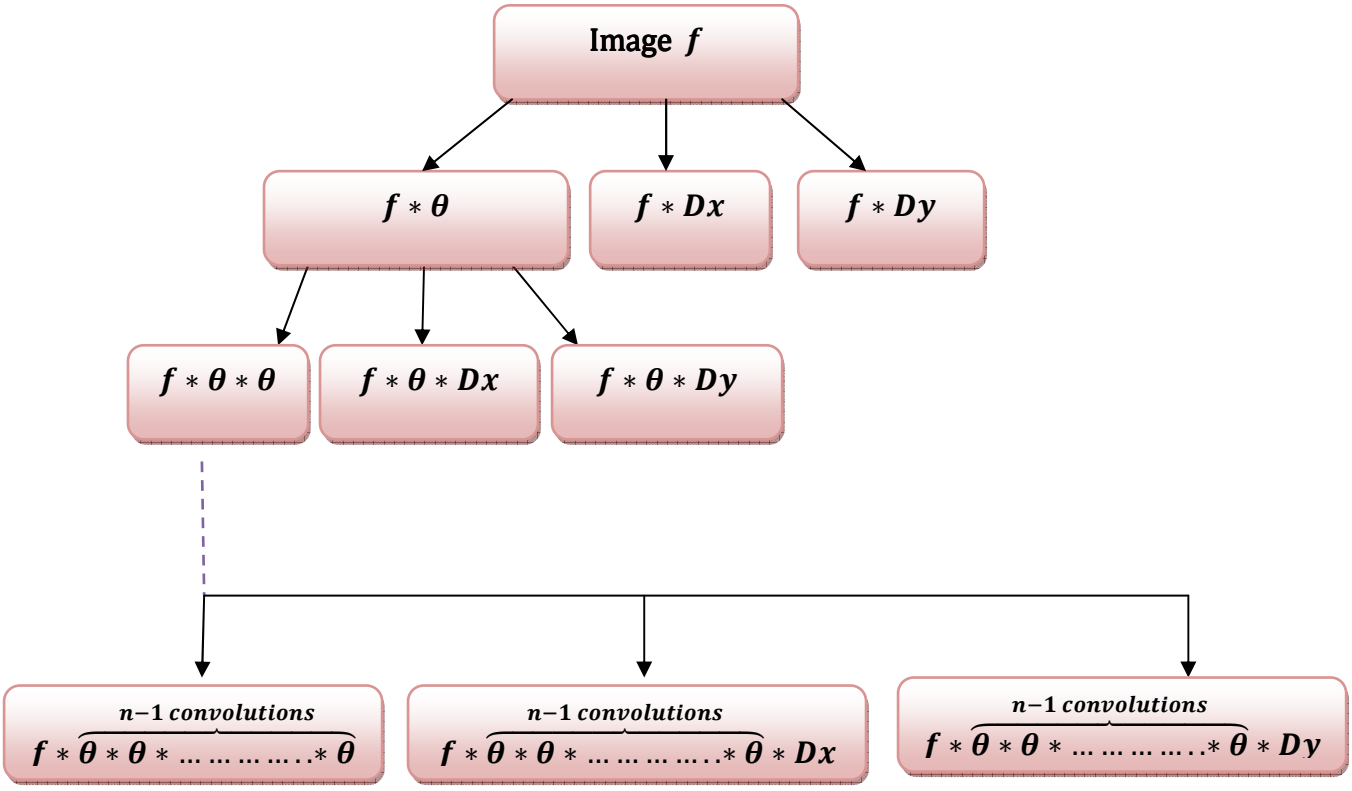

Figure.3.4. L'algorithme par convolution en cascade B-spline.

Pour effectuer la décomposition en gradient multi-échelle, Mallat et Zhong [50] ont construit une ondelette appartenant à la famille des Splines. Cette ondelette est associée à une décomposition discrète qui approxime la dérivée première d'une gaussienne, ce qui permet d'avoir certaines propriétés importantes :

- Compacité : puisqu'on effectue des convolutions, le nombre de coefficients h est forcément fini, et la fonction d'échelle est compacte.
- Régularité : c'est une condition essentielle pour éviter dans l'analyse des artefacts liés à l'irrégularité de la fonction d'échelle.

a. La B-spline

a.1. Définition monodimensionnelle

La B-spline de degré 0 est la fonction $\beta^0(x)$ qui vaut 1 pour $x \in \left[\frac{-1}{2}, \frac{1}{2}\right]$ et 0 ailleurs**.** La B-spline de degré n est obtenue par la convolution de n + 1 fonctions $\beta^0(x)$ (ce qui correspond à n convolutions) [38] [44]:

$$\overbrace{(x) = \beta^0(x) * \beta^0(x) * \dots\dots\dots\dots * \beta^0(x)}^{n\ convolutions} \qquad (3.20)$$

Le support d'une B-spline de degré n est $\left[-\frac{n+1}{2}, \frac{n+1}{2}\right]$

Les B-splines d'ordres 0, 1 et 3 sont tracées sur la figure.3.5.

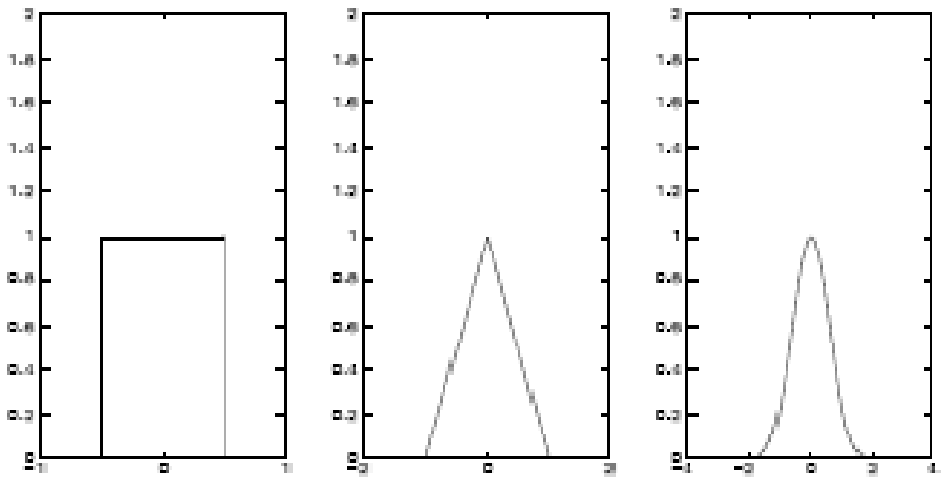

Figure.3.5. B-splines d'ordres 0, 1, et 3

a.2. B-spline discrète

La B-spline d'ordre 1 est donné par l'équation (3.21) :

$$b_1 = \frac{1}{4}[1\ 2\ 1] * \frac{1}{4}[1\ 2\ 1] \qquad (3.21)$$

$$= \frac{1}{16}\begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} \qquad (3.22)$$

3.7. Le détecteur multi-échelles de Canny

Pour travailler sur des fonctions bidimensionnelles, et en particulier des images, le détecteur de Canny, consiste à utiliser non plus une, mais deux transformées en ondelettes en utilisant des ondelettes Ψ^1 et Ψ^2 orientées (les dérivées suivant x et y d'un noyau de lissage).

Soit Ψ une ondelette bidimensionnelle dont les deux composantes sont les dérivées selon x et selon y d'une fonction B-spline $\Theta(x, y)$ [30] [46] [47].

$$\psi^1 = \frac{\partial \Theta}{\partial x} \qquad (3.23)$$

$$\psi^2 = \frac{\partial \Theta}{\partial y} \qquad (3.24)$$

Avec $\vec{\psi} = (\psi^1, \psi^2)$

Avec Θ un noyau de lissage que est positif et isotrope, à variables séparées ; il vérifiera:

$$\iint_{R^2} \Theta = 1 \qquad (3.25)$$

$\Theta(x, y)$ est isotrope où $\Theta(x, y) = \Theta_1(x).\Theta_2(x)$ (3.26)

On définit ainsi deux transformées en ondelettes, l'une détectant les singularités **verticales** et l'autre les singularités **horizontales** d'une image [48], dont les valeurs à l'échelle $\mathbf{a} \geq \mathbf{0}$ et au point (u, v)de R^2 sont:

$$W^1 f(u,v,a) = \iint_{R^2} \frac{1}{a} f(x,y) \psi^1 \left(\frac{x-u}{a}, \frac{y-v}{a}\right) dxdy = f * \check{\psi}^1(u,v) \qquad (3.27)$$

$$W^2 f(u,v,a) = \iint_{R^2} \frac{1}{a} f(x,y) \psi^2 \left(\frac{x-u}{a}, \frac{y-v}{a}\right) dxdy = f * \check{\psi}^2(u,v) \qquad (3.28)$$

Où

$$\psi^p(x,y) = \frac{1}{a}\psi^p(\frac{x}{a}, \frac{y}{a}) \quad \text{et} \quad \check{\psi}^p(x,y) = \psi^p(-x,-y) \text{ pour } p=1,2. \qquad (3.29)$$

Cette transformée peut être écrite sous forme vectorielle :

$$\vec{W} f(u,v,a) = \left(W^1 f(u,v,a), W^2 f(u,v,a)\right) = \left\langle f(x,y), \vec{\psi}_a(x-u, y-v\right\rangle \qquad (3.30)$$

Ainsi, en chaque point (u, v)de R^2, on connait, à une échelle a fixée, le vecteur

$$\vec{W} f(u,v,a) = (W^1 f(u,v,a), W^2 f(u,v,a)) \qquad (3.31)$$

Or, du fait que dérivation et convolution commutent, il vient que

$$W^1(u,v,a) = a\frac{\partial}{\partial u}\left(f * \check{\Theta}_a\right)(u,v) \qquad (3.32)$$

$$W^2 f(u,v,a) = a\frac{\partial}{\partial v}\left(f * \check{\Theta}_a\right)(u,v) \qquad (3.33)$$

Où

$$\check{\Theta}_a(x,y) = \frac{1}{a}\Theta(\frac{-x}{a}, \frac{-y}{a}) \qquad (3.34)$$

Et donc

$$\vec{W} f(u,v,a) = a\vec{\nabla}\left(f * \check{\Theta}_a\right)(u,v) \qquad (3.35)$$

La transformée qui à l'image f associe $\vec{W} f(u,v,a)$ est donc proportionnelle au gradient de l'image lissée par un noyau de convolution d'échelle a.

Plutôt que de représenter $\overrightarrow{\mathrm{W}}\mathrm{f}(\mathrm{u},\mathrm{v},\mathrm{a})$ par ses deux composantes $\mathrm{W}^1\mathrm{f}(\mathrm{u},\mathrm{v},\mathrm{a})$et $\mathrm{W}^2\mathrm{f}(\mathrm{u},\mathrm{v},\mathrm{a})$ il sera donc plus pratique, d'utiliser son module et son orientation [49] [50] [51].

$$Mf(u,v,a) = \sqrt{|W^1 f(u,v,a)|^2 + |W^2 f(u,v,a)|^2} \qquad (3.36)$$

Et $\quad Af(u,v,a) = tan^{-1}(\frac{W^2 f(u,v,a)}{W^1 f(u,v,a)}) \qquad si \quad W^1 f(u,v,a) \geq 0 \qquad (3.37)$

$$= \pi - tan^{-1}(\frac{W^2 f(u,v,a)}{W^1 f(u,v,a)}) \quad si \quad W^1 f(u,v,a) < 0 \qquad (3.38)$$

$Mf(u,v,a)$ est le module en (u,v) du gradient $(\frac{\partial(f*\Theta_a)}{\partial x}, \frac{\partial(f*\Theta_a)}{\partial y})$ de l'image f convoluée par un noyau de lissage à l'échelle a .

$Af(u,v,a)$ est l'orientation en (u,v) du gradient de l'image lissée par ce même noyau à l'échelle a **.**

Le lien entre la transformée en ondelette directionnelle $\overrightarrow{w_\theta} f(x,y,a,\theta)$ et le module et l'orientation est donné par l'équation (3.38).
θ représente la direction d'analyse.

$$\overrightarrow{w_\theta} f(x,y,a,\theta) = Mf(x,y,a) \begin{pmatrix} cos(\alpha-\theta) \\ sin(\alpha-\theta) \end{pmatrix} \qquad (3.39)$$

Avec $\quad \alpha = Af(x,y,a)$

3.8. Maximum local

3.8.1. Cas monodimensionnel

Un maximum (respectivement minimum) est un point en lequel f est plus grande (respectivement plus petite) qu'en ses voisins, ce qui peut se traduire mathématiquement par la définition suivante :

Soit f : $I \to R$ où $I \subset R;$ f est localement maximum (respectivement minimum) en $x_0 \in I$ s'il existe V $\subset$ I un voisinage de x_0 tel que $f(x_0) \geq f(x)$ (respectivement$f(x_0) \leq f(x)$) pour tout x dans V [53].

3.8.2. Cas bidimensionnel

On considère maintenant une fonction $f: R^2 \to R$. Soit $D_{(x_0,y_0)}$ un disque centrée sur (x_0, y_0) et telle que $f(x_0, y_0)$ soit supérieur (pour un maximum) ou inferieur (pour un minimum) à $f(x, y)$ pour tout (x, y) dans $D_{(x_0,y_0)}$.

Soit $f : I * j \to R$ ou I et j sont des intervalles ouverts ; f est localement maximum (respectivement minimum) en $(x_0, y_0) \in$ I × j s'il existe $D_{(x_0,y_0)}$ un disque ouvert centrée sur (x_0, y_0) tel que $f(x_0) \geq f(x)$ (respectivement$f(x_0) \leq f(x)$) pour tout x dans $D_{(x_0,y_0)}$ [53].

Notre algorithme consiste à déterminer les maxima à chaque échelle en chaque point de l'image. Pour cela, nous comparons le module maximal *Mf (x, y, a)* du pixel (*x, y*) à ses 8 voisins dans la direction du gradient. Puisque les images que nous manions sont des matrices discrètes, définies en un nombre fini de pixels, Il nous faut donc préciser ce que devient, pour des images numériques, la notion de maximum local [54].

Rappelons que *Mf (x, y, a*) désigne la carte des modules des coefficients d'ondelettes à l'échelle «*a*» tandis que *Af (x, y, a)* désigne l'orientation du gradient de l'image lissée par un noyau de convolution Θ_a .

Le pixel (*x* , *y*) a 8 voisins, les pixels qui l'entourent ; on conviendra que son voisin dans la direction θ est:

(x+1, y) *si* $\theta \in \left[-\frac{\pi}{8}, \frac{\pi}{8}\right[$

(x+1, y+1) *si* $\theta \in \left[\frac{\pi}{8}, \frac{3\pi}{8}\right[$

(x, y+1) *si* $\theta \in \left[3\frac{\pi}{8}, 5\frac{\pi}{8}\right[$

(x-1, y+1) *si* $\theta \in \left[5\frac{\pi}{8}, 7\frac{\pi}{8}\right[$

(x-1, y) *si* $\theta \in \left[7\frac{\pi}{8}, -7\frac{\pi}{8}\right[$

(x-1, y-1) *si* $\theta \in \left[-7\frac{\pi}{8}, -5\frac{\pi}{8}\right[$

(x, y-1) *si* $\theta \in \left[-5\frac{\pi}{8}, -3\frac{\pi}{8}\right[$

(x+1,y+1) *si* $\theta \in \left[-3\frac{\pi}{8}, -\frac{\pi}{8}\right[$

Pour décider si *Mf(x, y, a)* est un maximum local, on le compare au module en ses deux voisins dans les directions *Af(x, y, a)* et *-Af(x, y, a)* :

appelons les $Mf(x_1, y_1, a)$ et $Mf(x_2, y_2, a)$.Un maximum local de *Mf(x, y , a)* sera en fait un maximum local dans la direction *Af(x, y, a)* et sera défini en pratique comme suit :

Soit $\varepsilon > 0$ un seuil fixé. *Mf(x, y, a)* est un maximum local si :

$$Mf(x,y,a) - Mf(x_1,y_1,a) > \varepsilon \quad et \quad Mf(x,y,a) \geq Mf(x_2,y_2,a) \qquad \text{ou} \qquad (3.40)$$

$$Mf(x,y,a) - Mf(x_2,y_2,a) > \varepsilon \quad et \quad Mf(x,y,a) \geq Mf(x_1,y_1,a) \qquad (3.41)$$

$\varepsilon > 0$ Sert à ce que de petites oscillations ne génèrent pas de maximum local.

Ces maxima locaux sont détectés à chaque échelle : soit {***a***} une échelle fixée.

Si *Mf(x, y, a)* n'est pas un maximum local, on le met à 0 ainsi que *Af(x, y, a)*, Sinon il conserve sa valeur (voir figure 3.6).

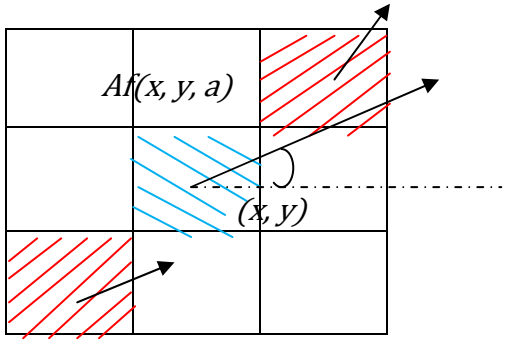

Figure. 3.6. Suppression d'un non maximum local

Af(x, y, a) étant compris entre $\frac{\pi}{8}$ et $\frac{3\pi}{8}$, les deux voisins dont les modules seront comparés à *Mf(x, y, a)* sont ceux hachurés de travers ; en l'occurrence, leurs modules (figurés par la taille des flèches) sont bien inférieurs à *Mf(x, y, a)* donc *Mf(x, y, a)* est un max local.

3.9. Le chaînage

Une fois les modules maximaux calculés à toutes les échelles, il faut chaîner les modules maximaux (maxima locaux) à travers les échelles (figure.3.7) [55]. Nous faisons une comparaison carte à carte afin de voir si, pour un pixel (x, y, a) correspondant à un module max, il existe, dans l'échelle inférieure, un pixel *(x, y, a−1)* et ses 8 voisins qui pourraient être liés à ce dernier. Pour cela, nous sélectionnons alors parmi ces 9 pixels celui dont la direction du gradient est proche de *Af (x, y, a).* Le point sélectionné caractérise un contour. Chacune de ces comparaisons faites deux à deux, jusqu'à l'échelle la plus fine.

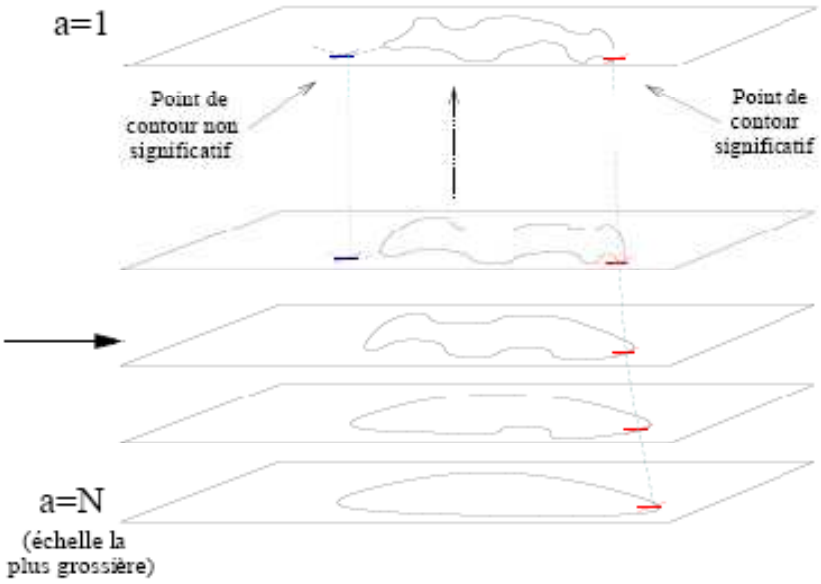

Figure.3.7. chainage à travers les échelles

3.10. Les différentes étapes du détecteur multi échelle de canny

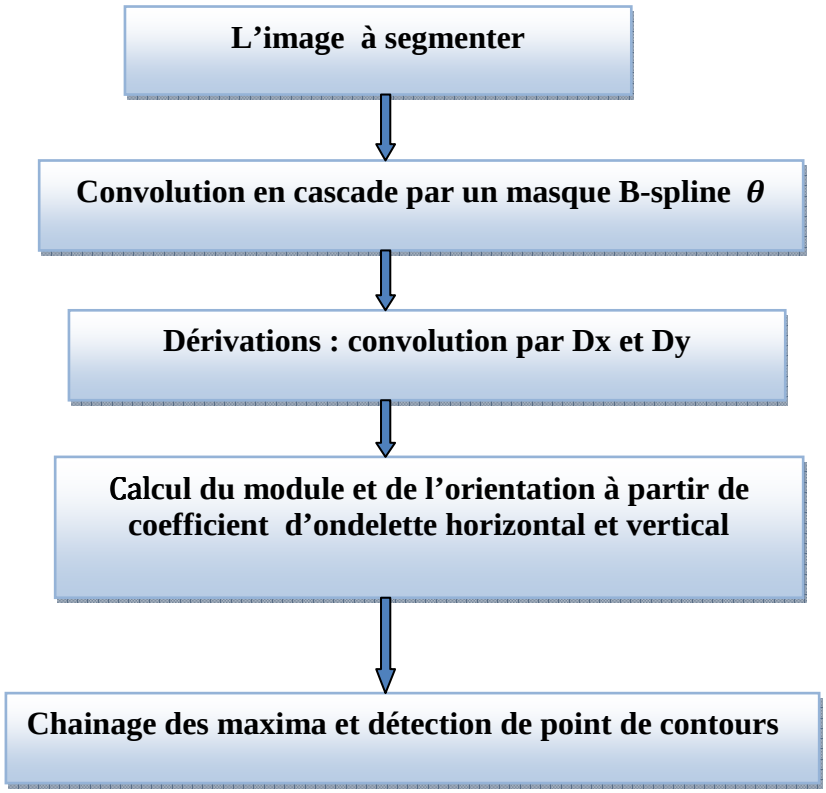

Figure.3.8.les différentes étapes du détecteur multi échelle de canny.

3.11. Discussion

Dans ce chapitre nous avons vu que la décomposition en échelles est réalisée par les ondelettes. Cette décomposition, peut être mise en œuvre par plusieurs algorithme tels que, l'algorithme de Mallat, l'algorithme à trous et l'algorithme par convolution en cascade B-splines. Nous avons montré que ce dernier est le plus adapté pour la détection de contours et leurs chainages.

L'application du détecteur multi échelle de canny sur des images IRM d'un cerveau sain et des images IRM d'un cerveau atteint d'une tumeur sera présenté dans le prochain chapitre afin d'évaluer son efficacité.

Chapitre 4

Applications du détecteur multi échelles de canny à des images IRM

CHAPITRE 4

APPLICATION DU DETECTEUR MULTI ECHELLES DE CANNY A DES IMAGES IRM

4.1. Préambule

Apres avoir donné les différentes étapes de la méthode de segmentation élaborée dans le chapitre précédant, nous allons présenter dans ce chapitre son algorithme d'application. Afin d'évaluer les performances de ce dernier des tests ont été réalisée sur des images IRM du cerveau, l'un est sain l'autre est atteint d'une tumeur.

Une comparaison sera effectuée entre les deux images pour pouvoir distinguer la tumeur des autres composantes du cerveau.

Pour montrer l'efficacité de la méthode une comparaison avec l'approche de canny classique sera réalisée.

4.2. Description de l'algorithme

4.2.1. Conversion de l'image en matrice

L'image est convertie en un tableau de flottant : elle sera notée $f(x;\ y)$,
Où $1 \leq x < width$ et $1 \leq y < height$. (width est la largeur de l'image et height sa hauteur).

4.2.2. Convolution en cascade de l'image par un masque B-spline θ

Cette étape consiste à convoluer itérativement f par le masque B-spline

$$\theta = \frac{1}{4}[1\ 2\ 1] * \frac{1}{4}\begin{bmatrix} 1 \\ 2 \\ 1 \end{bmatrix} \qquad \textbf{(4.1)}$$

On effectue donc la convolution par $\frac{1}{4}[1\ 2\ 1]$ d'abord sur les lignes, ensuite sur les colonnes de l'image. A l'aide de cette convolution on obtient $f_1 = f * \theta$ on recommence ensuite avec f_1, et ce autant de fois que l'on désire acquérir d'échelles. Au bout de $n-1$ convolutions, on obtient donc la matrice :

$$\boldsymbol{f_n = f * \overbrace{\theta * \theta * \ldots\ldots\ldots\ldots * \theta}^{n-1\ convolutions}} \qquad \textbf{(4.2)}$$

De même taille que l'image initiale

4.2.3. Dérivations : convolution par Dx et Dy

Pour chaque n, on dérive f lissée par $\overbrace{\theta * \theta * \ldots\ldots\ldots\ldots * \theta}^{n-1\ convolutions}$ en convoluant f_n par Dx d'une part (dérivation horizontale) et par Dy d'autre part (dérivation verticale).

Avec : $\boldsymbol{Dx = [o\ 1 - 1]}$ et $\boldsymbol{Dy} = \begin{bmatrix} \mathbf{0} \\ \mathbf{1} \\ \mathbf{-1} \end{bmatrix}$

On obtient à l'issue de cette étape les coefficients d'ondelettes

$$\boldsymbol{w^1 f(.,.,n) = f * \overbrace{\theta * \theta * \ldots\ldots\ldots\ldots * \theta}^{n-1\ convolutions} * Dx} \qquad \textbf{(4.3)}$$

$$\boldsymbol{w^2 f(.,.,n) = f * \overbrace{\theta * \theta * \ldots\ldots\ldots\ldots * \theta}^{n-1\ convolutions} * Dy} \qquad \textbf{(4.4)}$$

4.2.4. Calcul du module et de l'orientation du gradient de l'image à partir des coefficients d'ondelette horizontaux et verticaux.

$$\boldsymbol{wf(u,v,a) = \sqrt{|w^1 f(u,v,a)|^2 + |w^2 f(u,v,a)|^2}} \qquad \textbf{(4.5)}$$

$$\boldsymbol{Af(u,v,a) = tan^{-1}\left(\frac{w^2 f(u,v,a)}{w^1 f(u,v,a)}\right)} \quad \textbf{si} \quad \boldsymbol{w^1 f(u,v,a) \geq 0} \qquad \textbf{(4.6)}$$

$$\boldsymbol{= \pi - tan^{-1}\left(\frac{w^2 f(u,v,a)}{w^1 f(u,v,a)}\right)} \quad \textbf{si} \quad \boldsymbol{w^1 f(u,v,a) < 0} \qquad \textbf{(4.7)}$$

A chaque échelle, nous avons fait un seuillage sur les coefficients d'ondelettes de façon à ce que soient éliminés ceux dont le module est faible, qui correspond ou pas une arête peu visible.

4.2.5. Chainage des maximas locaux et détection de point de contours

Détection, à chaque échelle n, des maxima locaux de $Mf(:;:;n)$. On met à zéro les coefficients qui ne sont pas des maxima locaux. Nous chaînons à travers les échelles$n$, à l'aide de l'orientation $Af(:;:;n)$, les maxima correspondant à un même point de l'image initiale. Le sommet (à l'échelle 1) d'une chaîne est considéré comme un point de contour.

Dans notre application, la décomposition multi échelle a été effectuée jusqu'à l'échelle 30.

4.3. Résultats obtenus de l'application de notre algorithme à des images Test

4.3.1. Application à l'image Fields

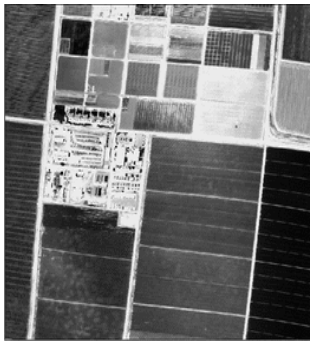

Image Fields

4.3.1.1. Singularités verticales

Echelle 1 **Echelle 10** **Echelle 20**

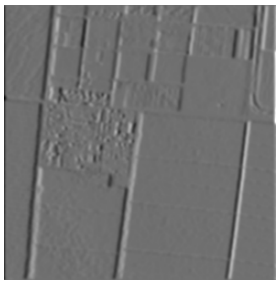
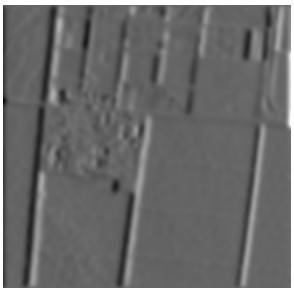
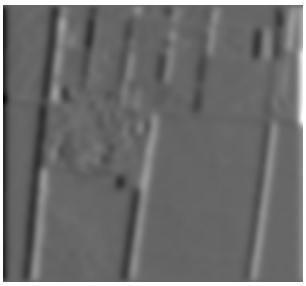

4.3.1.2. Singularités horizontales

Echelle 1 **Echelle 10** **Echelle 20**

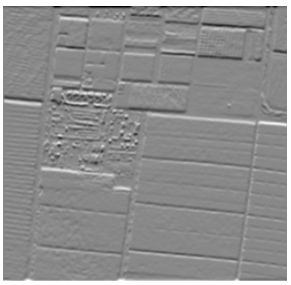
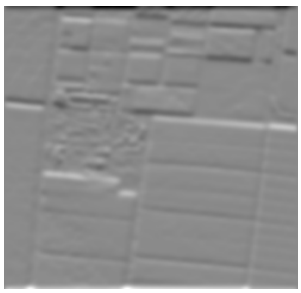
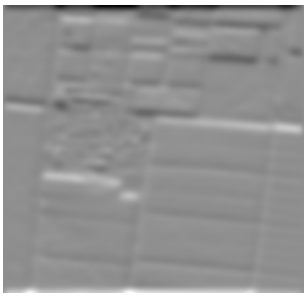

4.3.1.3. Cartes des modules et des orientations du gradient

Echelle 1 **Echelle 10** **Echelle 20**

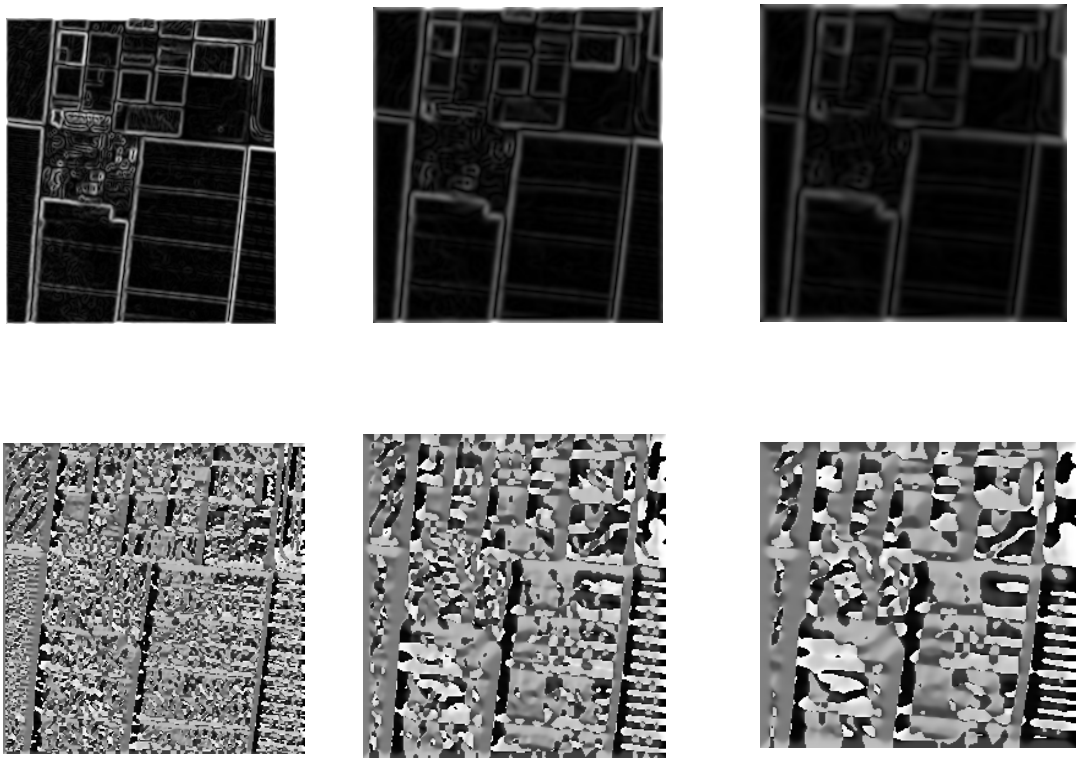

4.3.1.4. Maximas locaux du gradient

Echelle 1 **Echelle 10** **Echelle 20**

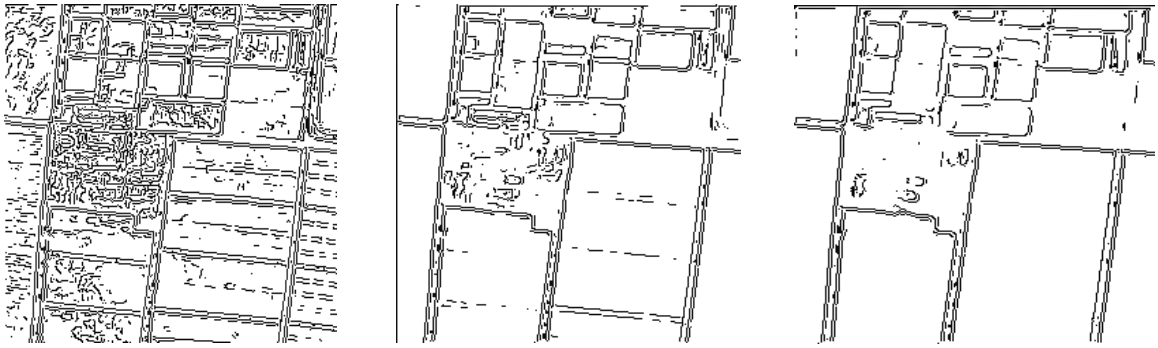

4.3.1.5. Résultat obtenu après chainage des maximas locaux du gradient

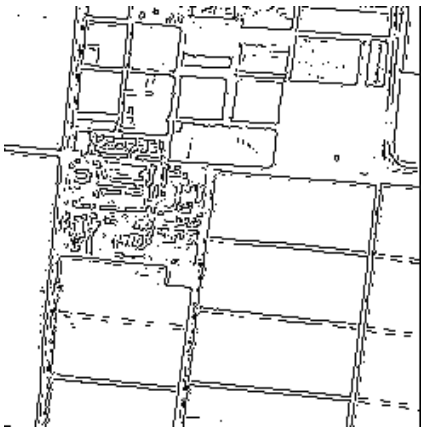

4.3.2. Application à l'image Cameraman

Image Cameraman

4.3.2.1. Singularités verticales

Echelle 1 **Echelle 10** **Echelle 20**

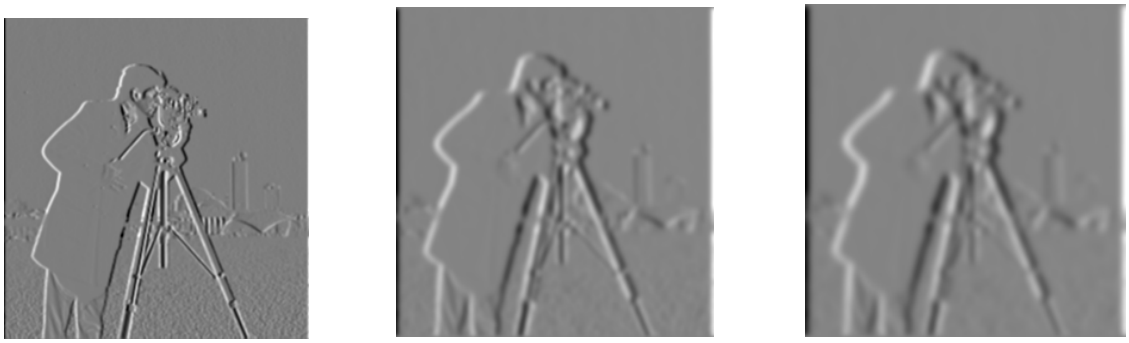

4.3.2.2. Singularités horizontales

Echelle 1 **Echelle 10** **Echelle 20**

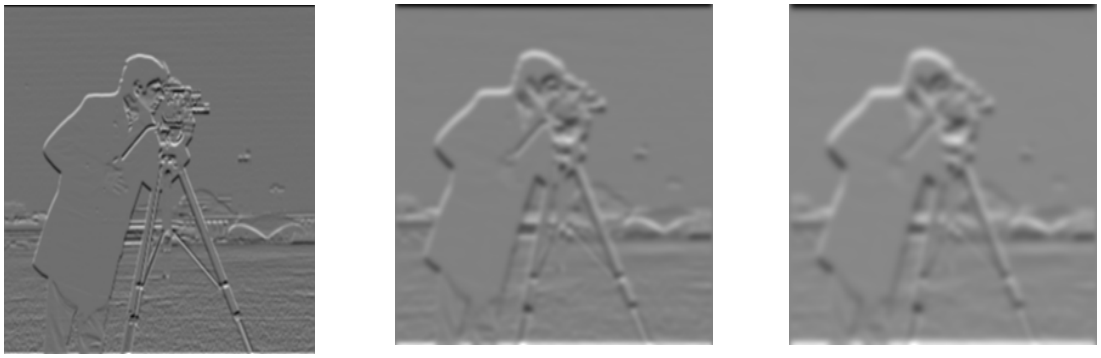

4.3.2.3. Cartes des modules et des orientations du gradient

Echelle 1 **Echelle 10** **Echelle 20**

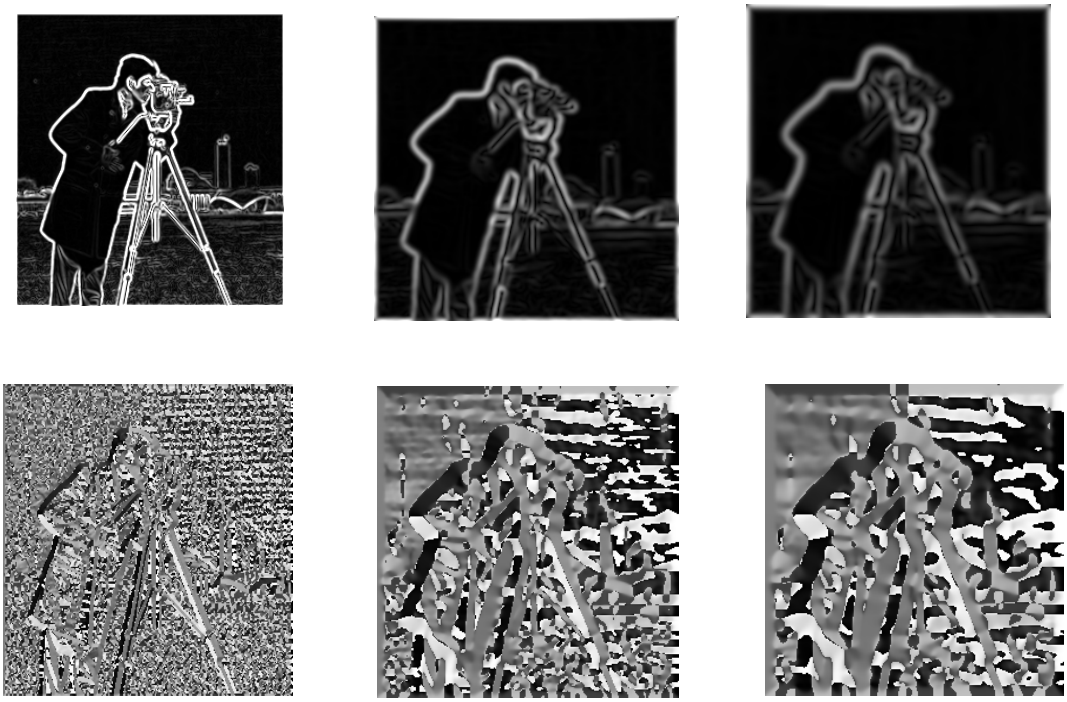

4.3.2.4. Maximas locaux du gradient

Echelle 1 **Echelle 10** **Echelle 20**

4.3.2.5. Résultat obtenu après chainage des maximas locaux du gradient

4.3.3. Application à l'image Suzan

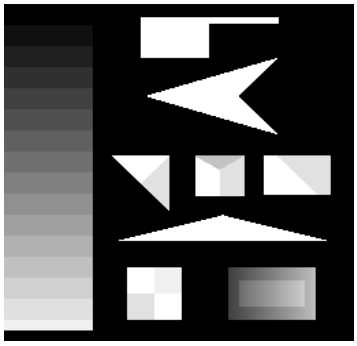

Image Suzan

4.3.3.1. Singularités verticales

Echelle 1 **Echelle 10** **Echelle 20**

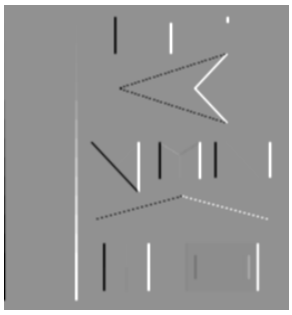

4.3.3.2. Singularités horizontales

Echelle 1 **Echelle 10** **Echelle 20**

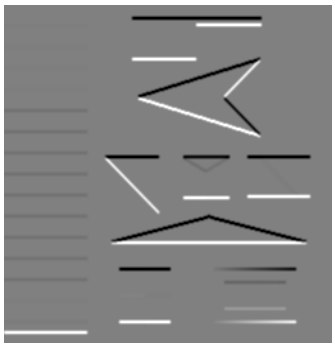

4.3.3.3. Cartes des modules et des orientations du gradient

Echelle 1 **Echelle 10** **Echelle 20**

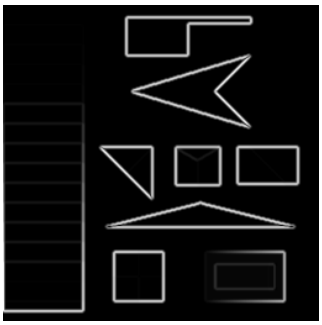

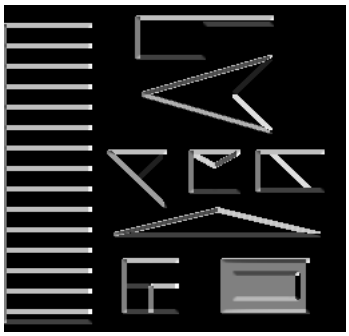
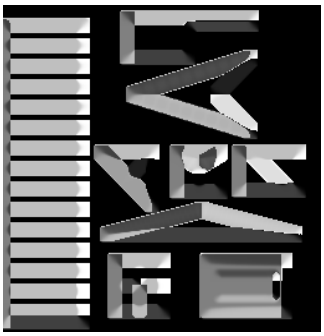
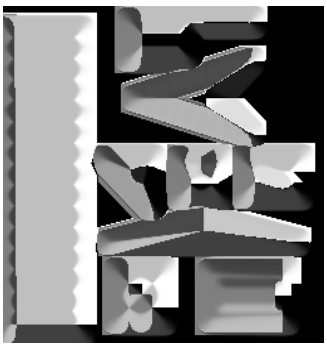

4.3.3.4. Maximas locaux du gradient

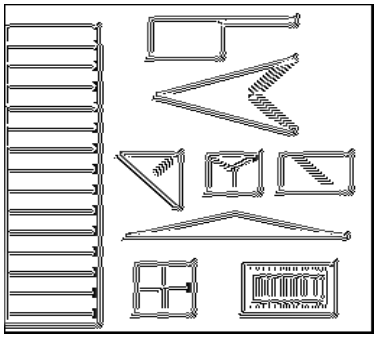
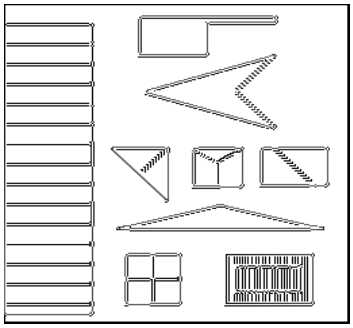
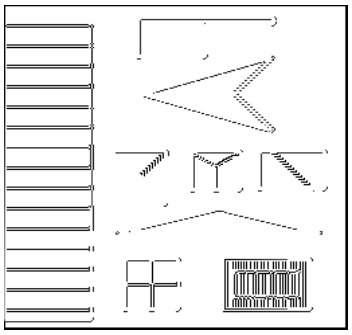

4.3.3.5. Résultat obtenu après chainage des maximas locaux du gradient

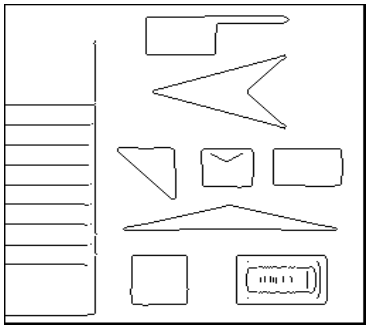

4.4. Présentation des données

Les données que nous avons utilisées sont constituées de deux sortes d'images :

- Une image IRM du cerveau sain d'un jeune homme né le 18/11/1983 originaire de Tizi-Ouzou prise le 18/11/2OO8.
- Une image IRM du cerveau d'une femme née le 29/11/1932 originaire d'ANNABA, prise le 29/11/2008 à 9H41. Atteinte d'une tumeur dans le cerveau (un méningiome frontale).

4.4.1 Image du cerveau sain

Le cerveau sain est composé de substance (ou matière) grise et de substance blanche, le tout baigne dans un liquide appelé liquide céphalo-rachidien(LCR).

L'image est de pondérationT1 (coupe axiale) de taille 512*512*8bits, (voir figure.5.1).

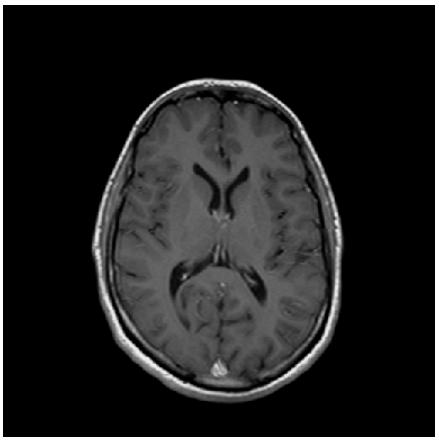

Figure.4.1. image IRM d'un cerveau sain

4.4.2. Image du cerveau atteint d’un méningiome frontal

Le cerveau atteint d’une tumeur à la même composition que le cerveau sain mais présentant un méningiome frontal.

C’est une image de pondération T1 (coupe axiale) avec injection gadolinium, elle est de taille 448*448*8 bits. (Voir figure.5.2).

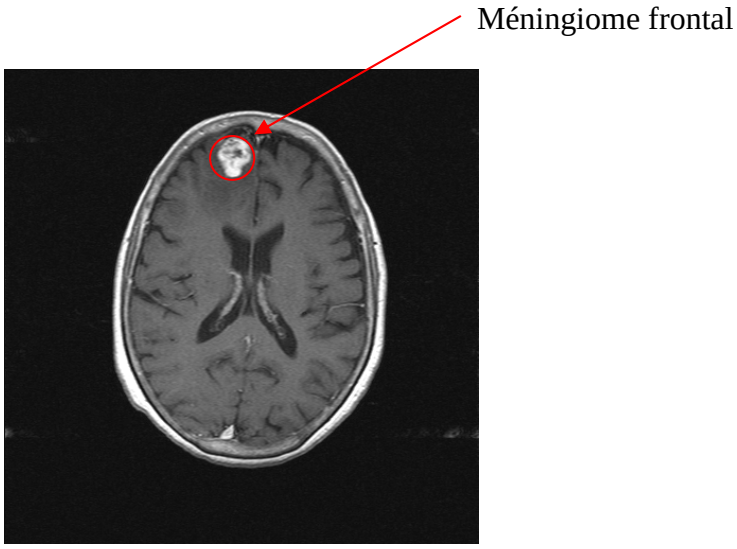

Figure.4.2. Image IRM du cerveau atteint d’un méningiome frontal

4.5. Résultats obtenus de l’application de notre algorithme sur une image IRM du cerveau sain

4.5.1. Lissage de l’image

Les résultats obtenus par le lissage de l’image par le noyau B-spline sont donnés par la figure4.3.

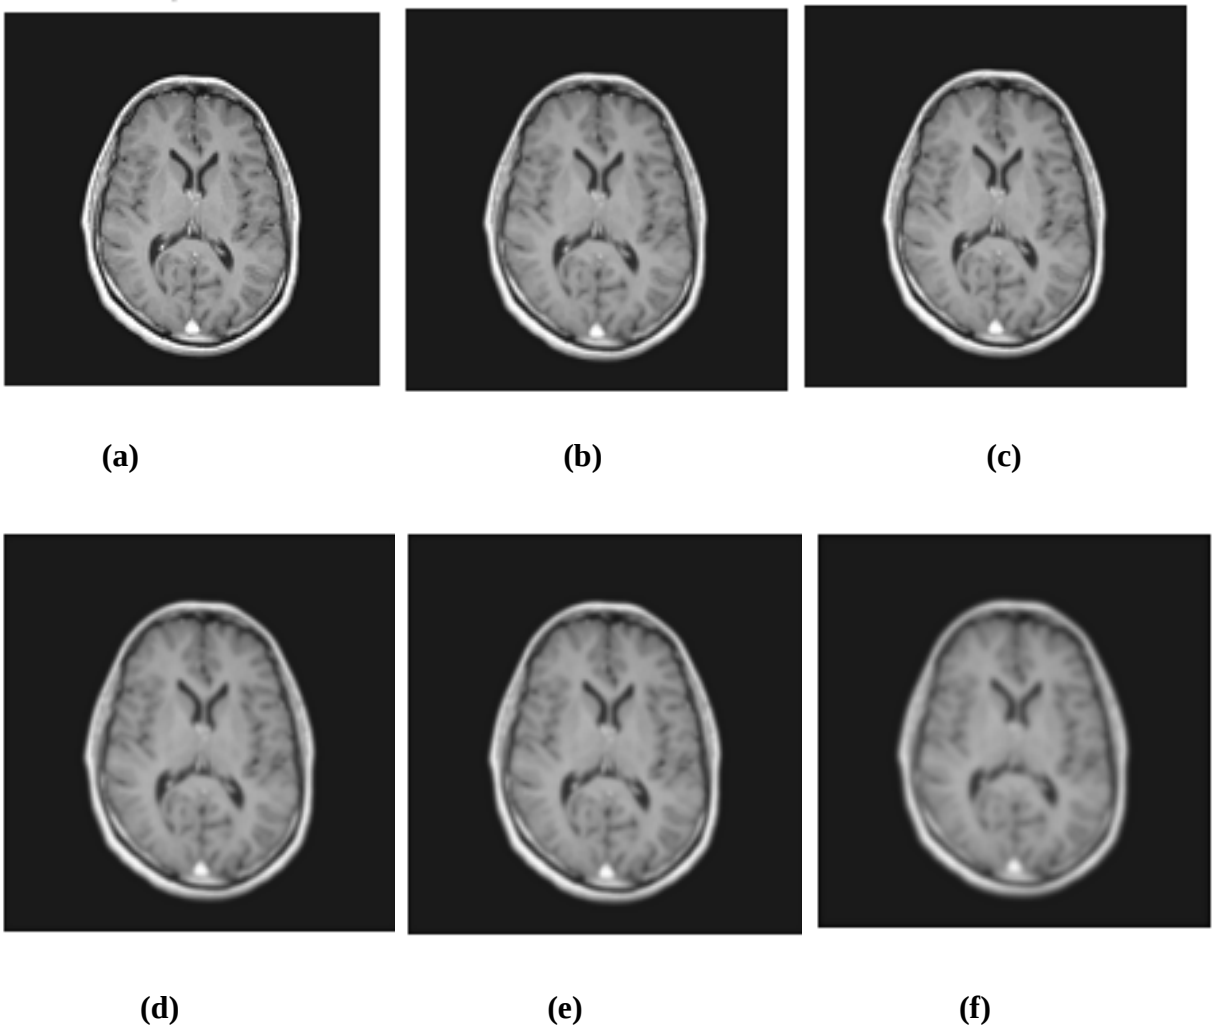

Figure.4.3. image lissée en plusieurs échelles.

(a) image à l’échelle 1.

(b) image lissée à l’échelle 6**. (c)** image lissée à l’échelle 10.

(d) image lissée à l’échelle 15**. (e)** image lissée à l’échelle 20. **(f)** image lissée à l’échelle 30.

4.5.2. Singularités verticales

Les résultats des singularités verticales sont donnés par la figure 4.4

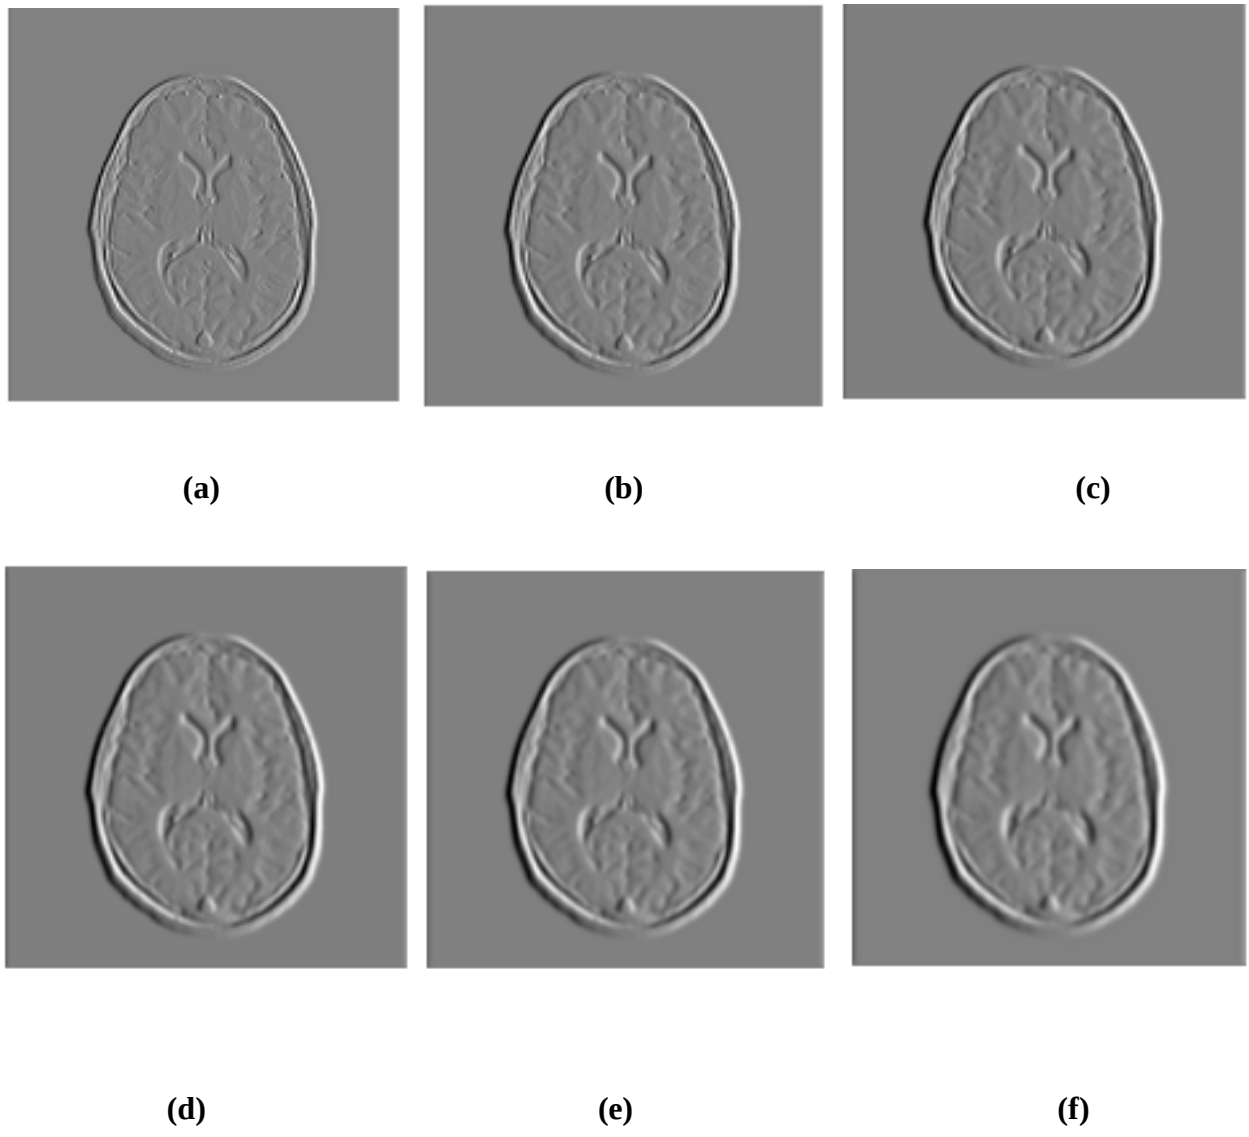

(a) **(b)** **(c)**

(d) **(e)** **(f)**

Figure.4.4. singularités verticales en plusieurs échelles.

(a) singularités verticales l'échelle1. **(b)** singularités verticales à l'échelle 6. **(c)** singularités verticales à l'échelle 10. **(d)** singularités verticales à l'échelle 15. **(e)** singularités verticales à l'échelle 20. **(f)** singularités verticales à l'échelle 30.

4.5.3. Singularités horizontales

Les résultats des singularités horizontales sont illustrés par la figure 4.5

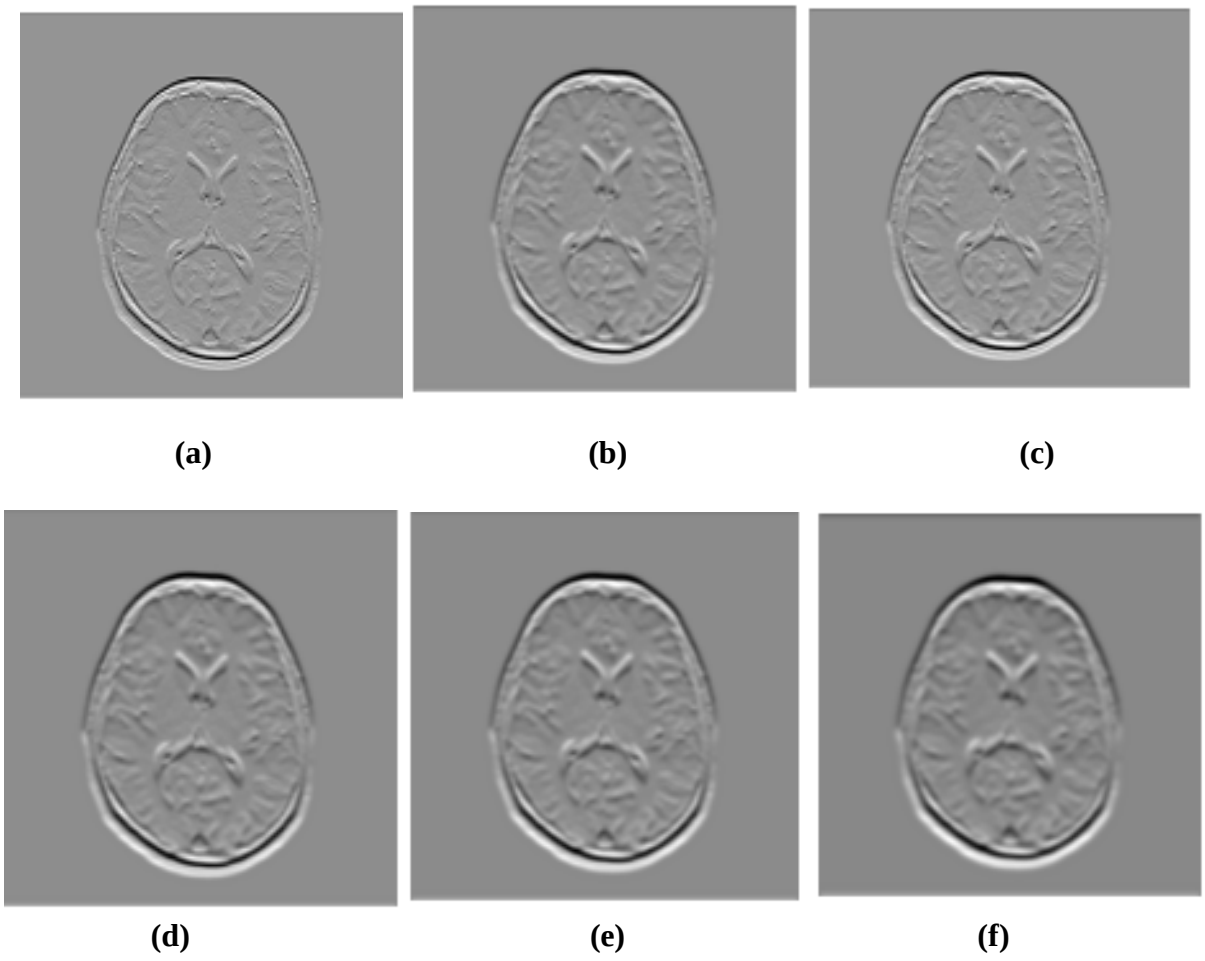

Figure.4.5. singularités horizontales en plusieurs échelles.

(a) singularités horizontales l'échelle1. **(b)** singularités horizontales à l'échelle 6**. (c)** singularités horizontales à l'échelle 10. **(d)** singularités horizontales à l'échelle 15. **(e)** singularités horizontales à l'échelle 20. **(f)** singularités horizontales à l'échelle 30.

4.5.4. Module du gradient de l’image

Les différentes cartes de modules du gradient sont données par la figure4.6

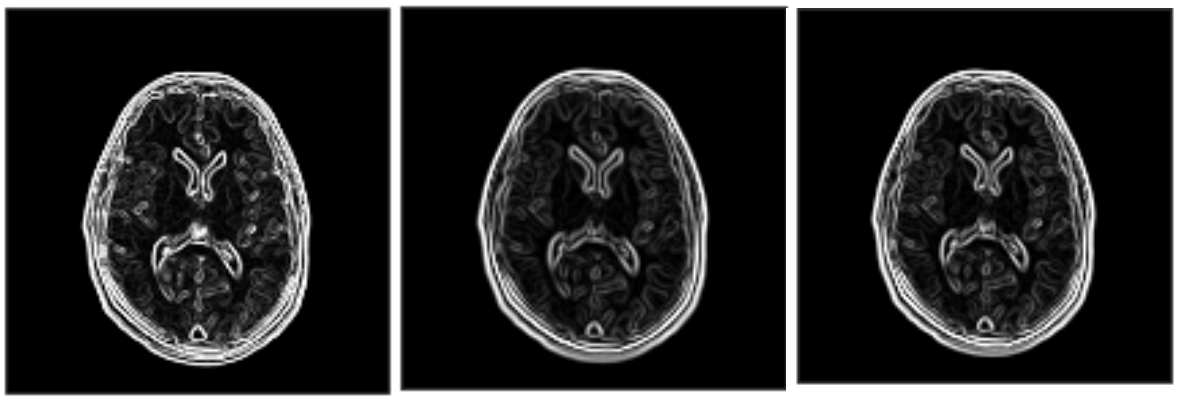

(a) **(b)** **(c)**

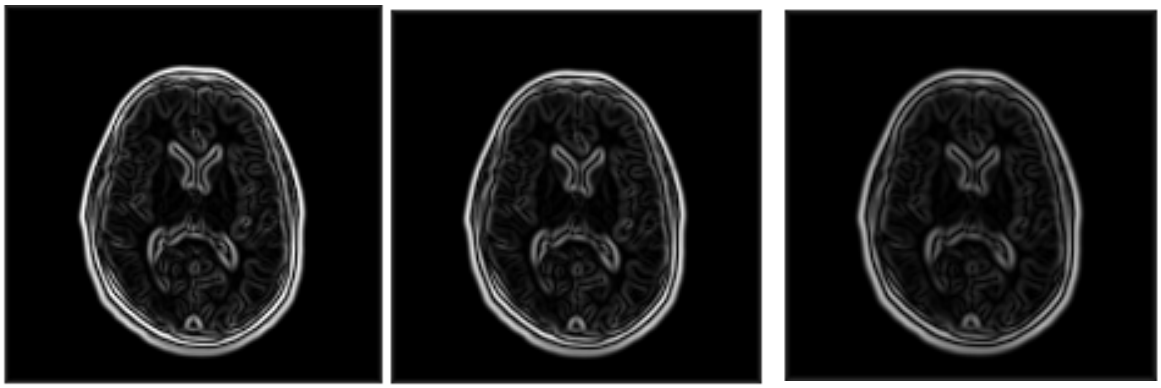

(d) **(e)** **(f)**

Figure.4.6. module du gradient en plusieurs échelles.

(a) module du gradient à l’échelle1. **(b)** module du gradient à l’échelle 6. **(c)** module du gradient à l’échelle 10. **(d)** module du gradient à l’échelle 15. **(e)** module du gradient à l’échelle 20. **(f)** module du gradient à l’échelle 30.

4.5.5. Orientations du gradient de l'image

Les cartes des orientations du gradient sont données par la figure4.7

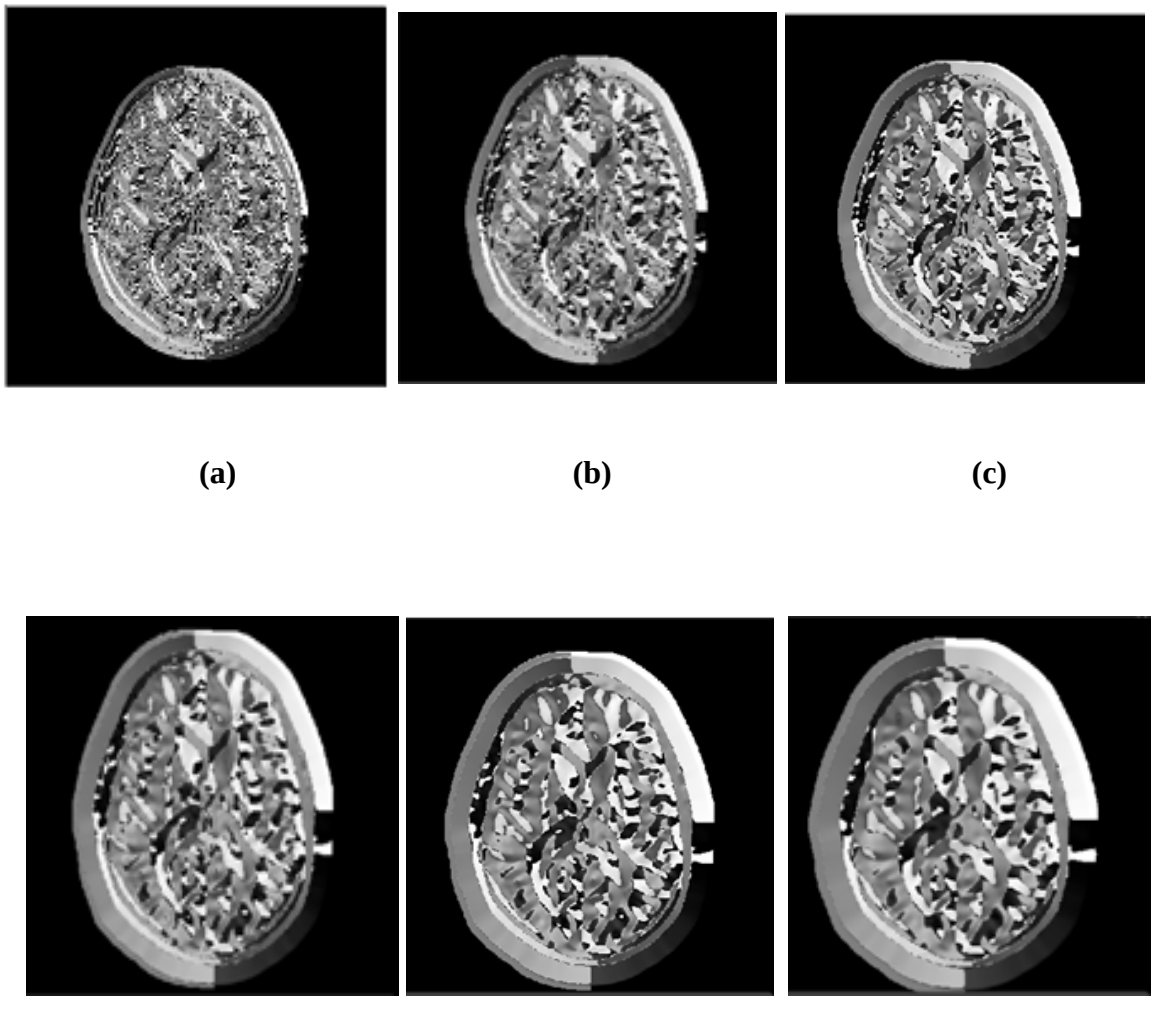

(a) **(b)** **(c)**

(d) **(e)** **(f)**

Figure.4.7. carte des orientations du gradient en plusieurs échelles.

(a)cartes des orientations du gradient à l'échelle1. **(b)** cartes des orientations du gradient à l'échelle 6. **(c)** cartes des orientation du gradient à l'échelle 10.**(d)** cartes des orientation du gradient à l'échelle 15. **(e)** cartes des orientations à l'échelle 20. **(f)** cartes des orientations à l'échelle 30.

4.5.6. Maximas locaux

Les cartes des maximas locaux sont données par la figure4.8

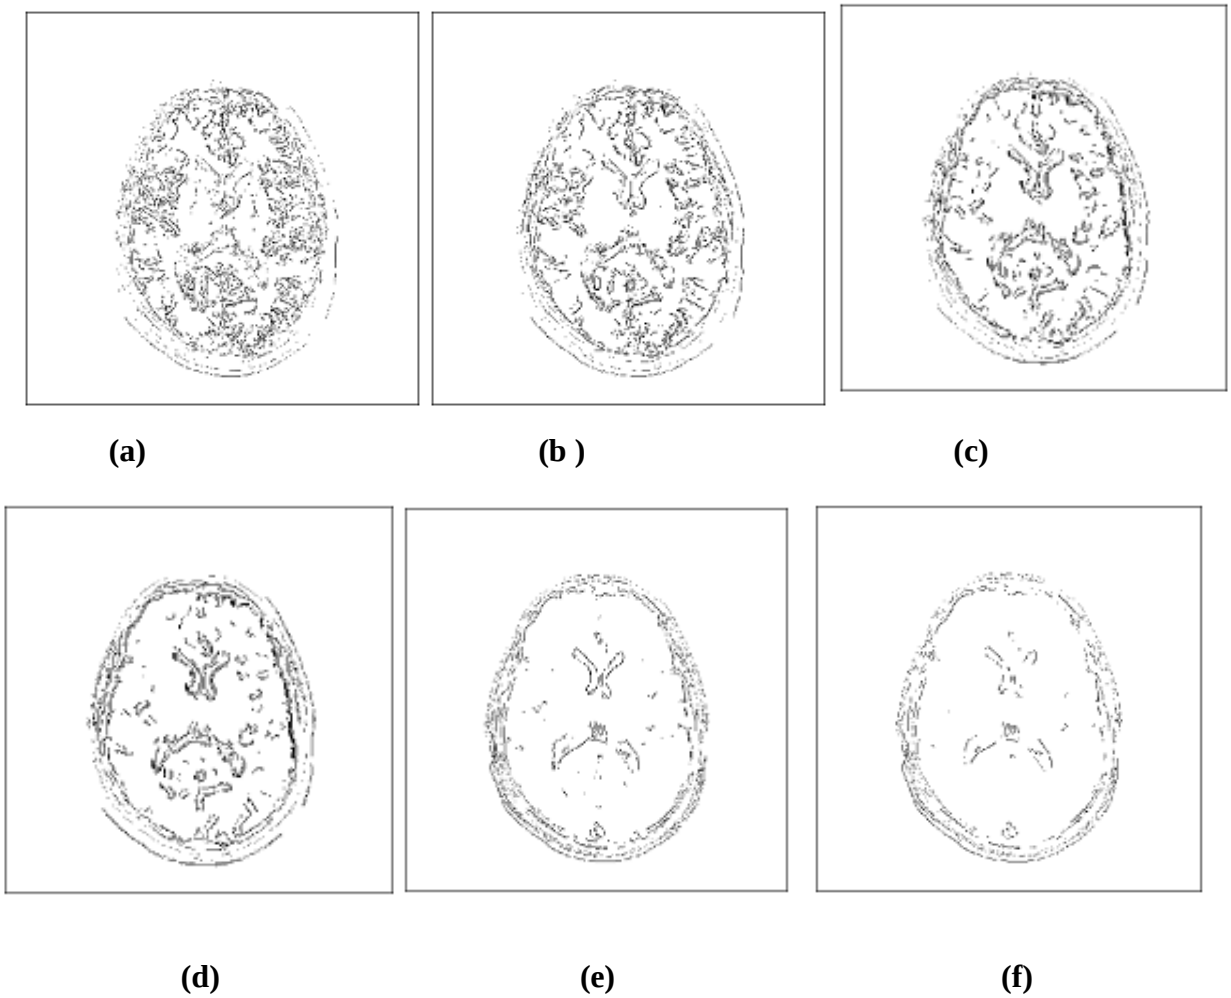

Figure.4.8. maximas locaux en plusieurs échelles.

(a) maximas locaux à l'échelle1. **(b)** maximas locaux à l'échelle 6. **(c)** maximas locaux à l'échelle 10. **(d)** maximas locaux à l'échelle 15. **(e)** maximas locaux à l'échelle 20. **(f)** maximas locaux à l'échelle30.

4.5.7. Résultat après chainage

Le résultat après chainage est illustré par la figure4.9

Fig.4.9. résultat après chainage.

4.5.8. Interprétation des resultats

La figure 4.4 et la figure 4.5 montrent que les singularités horizontales et verticales sont bien détectées. Lorsque nous partons des échelles fines vers les échelles grossières nous remarquons que la qualité des images diminue ce qui est dû au flou induit par l'opération de lissage (figure4.3).

A partir des singularités horizontales et verticales, nous obtenons les cartes des modules du gradient (figure4.6). L'analyse de ces dernières montre qu'aux petites échelles nous arrivons à détecter les détails les plus fins, et en allant vers les échelles grossières, seuls les détails important sont présents.

Les cartes des maximas-locaux (figure4.8) sont obtenues en combinant les cartes des orientations (figure4.7) et celles des modules du gradient (figure4.6). Nous constatons alors que sur les échelles fines des maximas locaux nous ne pouvons pas distinguer les différentes composantes du cerveau, ce qui est dû à la détection des pics du bruit. Sur les échelles intermédiaires nous remarquons que seuls les contours significatifs et les frontières entres les composantes du cerveau sont détectées. A partir des échelles grossières les composantes du cerveau disparaissent.

Après chaînage (figure4.9) nous retrouvons les contours les plus communs entres les échelles, par conséquent les contours les plus significatifs, ainsi que les frontières des composantes du cerveau.

4.6. Résultat obtenus par l'application de notre algorithme sur l'IRM du cerveau atteint d'un méningiome.

4.6.1 Lissage

Les résultats obtenus par le lissage de l'image par le noyau B-spline sont donnés par la figure 4.10.

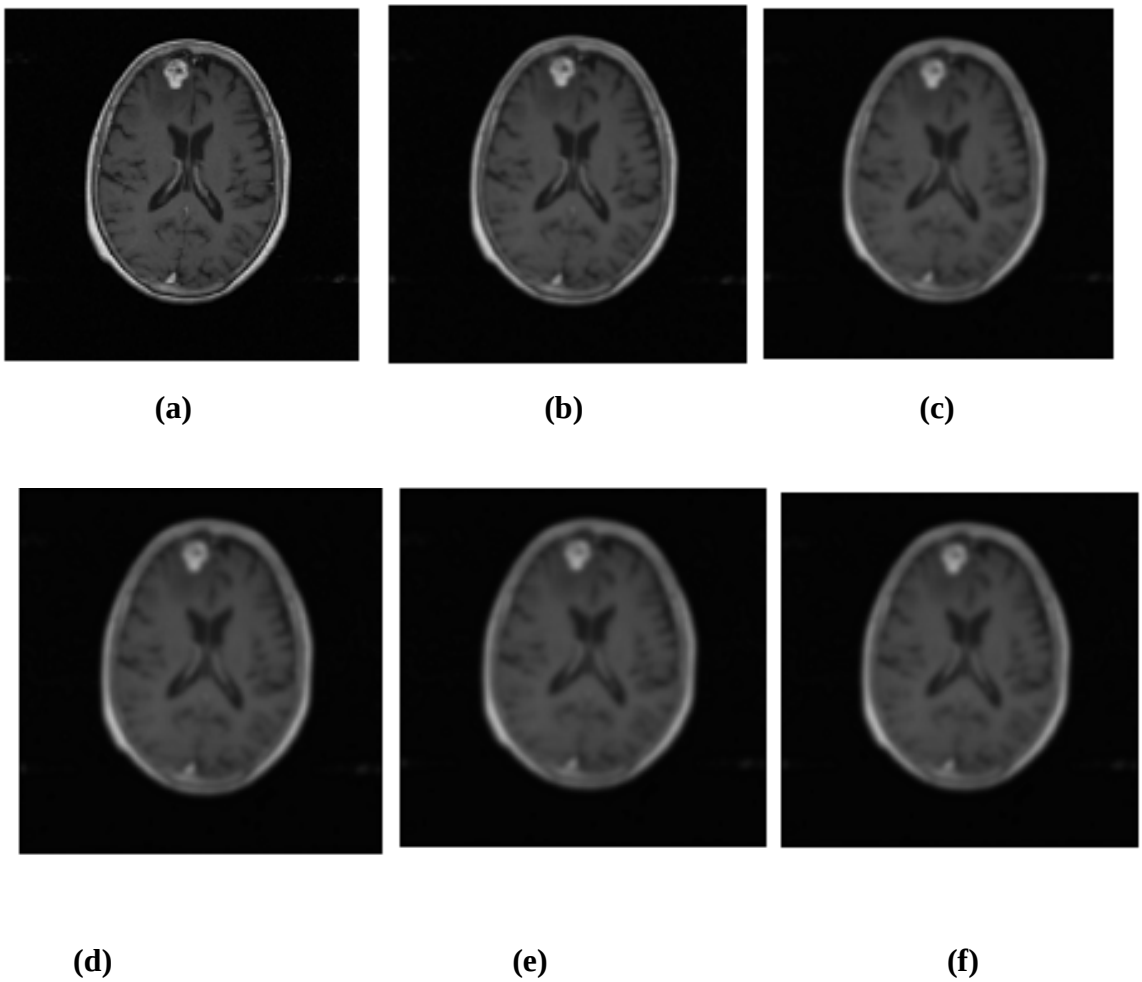

(a) **(b)** **(c)**

(d) **(e)** **(f)**

Figure.4.10. image lissé en plusieurs échelles.

(a) image lissé à l'échelle1. **(b)** image lissé à l'échelle 6. **(c)** image lissé à l'échelle 10.

(d) image lissé à l'échelle 15. **(e)** image lissé à l'échelle 20. **(f)** image lissé à l'échelle 30.

4.5.2 Singularités verticales

Les résultats des singularités verticales sont illustrés par la figure 4.11

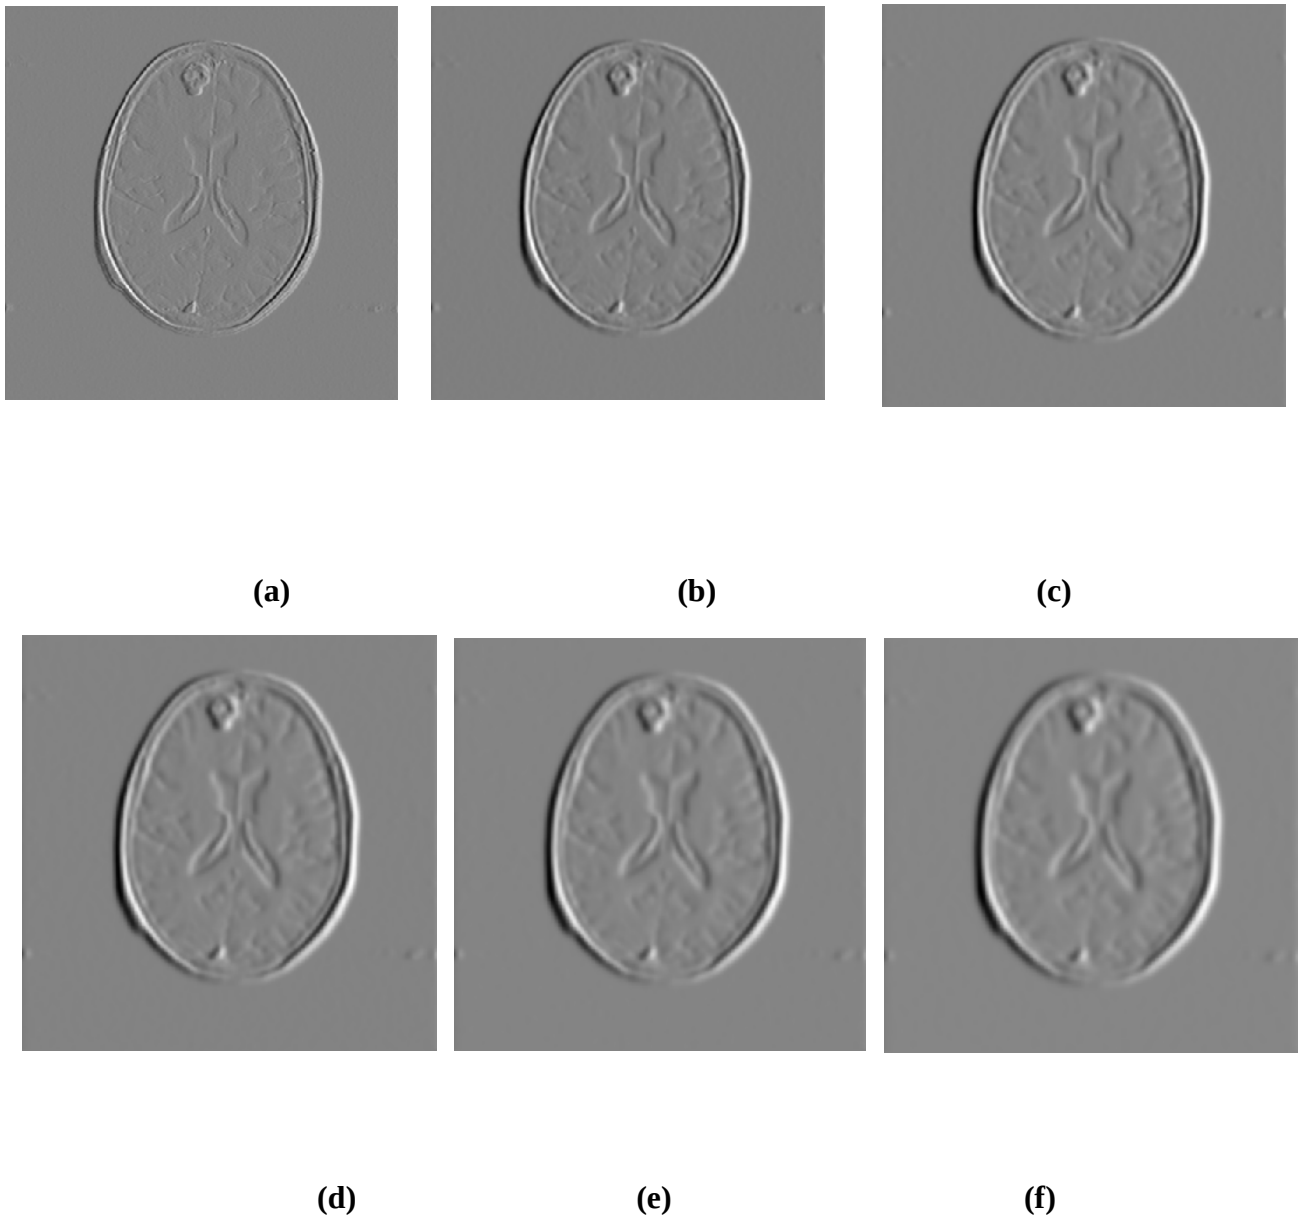

(a) **(b)** **(c)**

(d) **(e)** **(f)**

Figure.4.11. singularités verticales en plusieurs échelles.

(a) singularités verticales l'échelle1. **(b)** singularités verticales à l'échelle 6. **(c)** singularités verticales à l'échelle 10. **(d)** singularités verticales à l'échelle 15. **(e)** singularités verticales à l'échelle 20**. (f)** singularités verticales à l'échelle 30.

4.6.3 Singularités horizontales

Les résultats des singularités horizontales sont illustrés par la figure 4.12

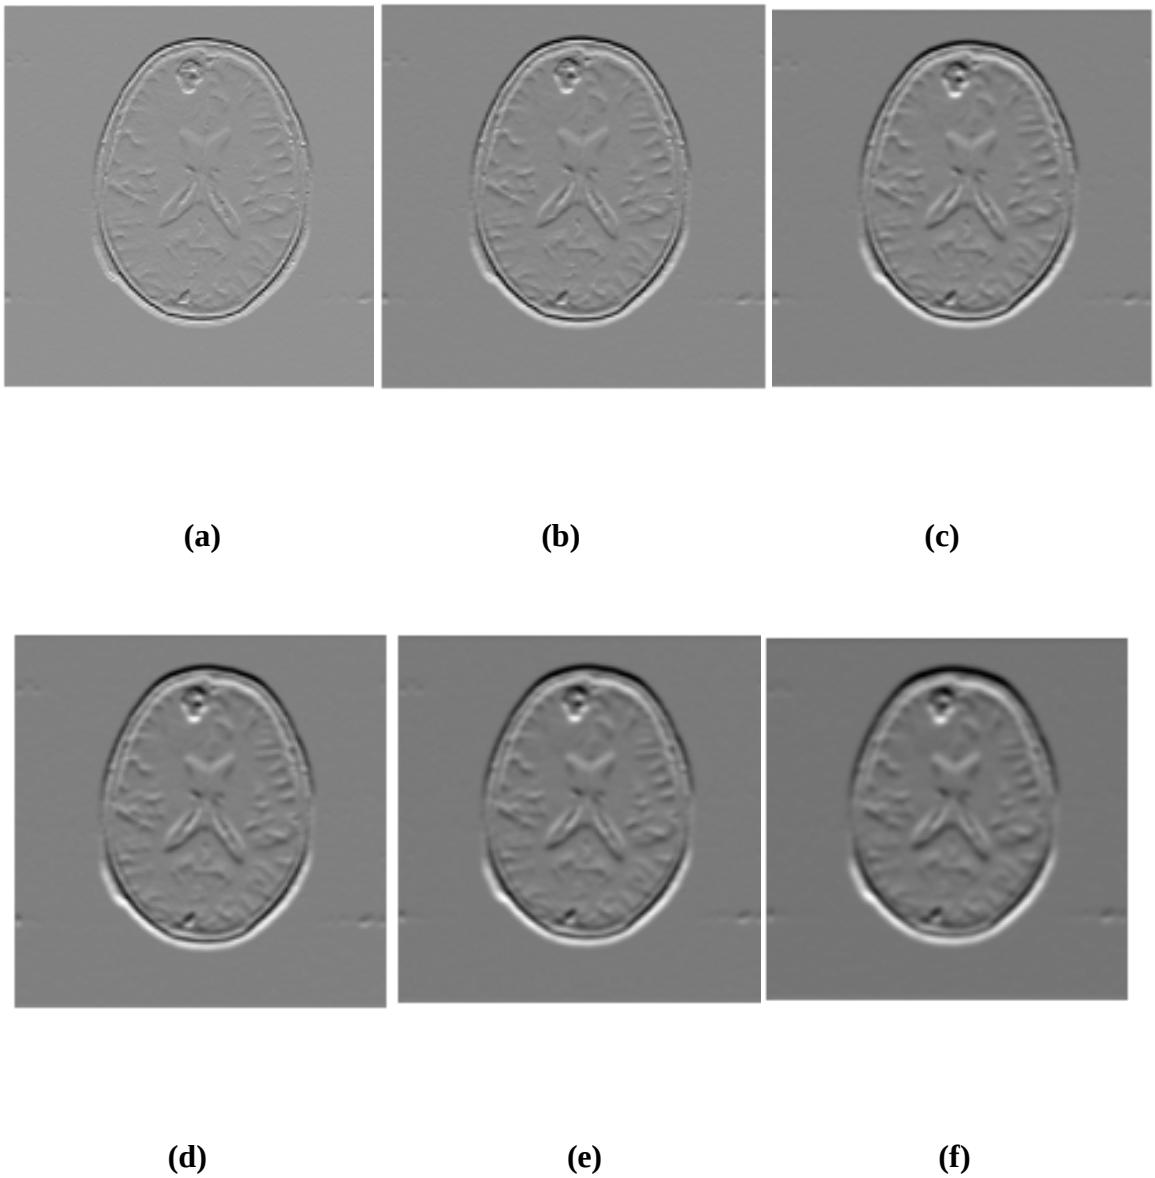

(a) **(b)** **(c)**

(d) **(e)** **(f)**

Figure.4.12. singularités horizontales en plusieurs échelles.

(a) singularités horizontales l'échelle1. **(b)** singularités horizontales à l'échelle 6. **(c)** singularités horizontales à l'échelle 10. **(d)** singularités horizontales à l'échelle 15. **(e)** singularités horizontales à l'échelle 20. **(f)** singularités horizontales à l'échelle 30.

4.6.4 Module du gradient de l’image

Les différentes cartes de modules du gradient sont données par la figure4.13

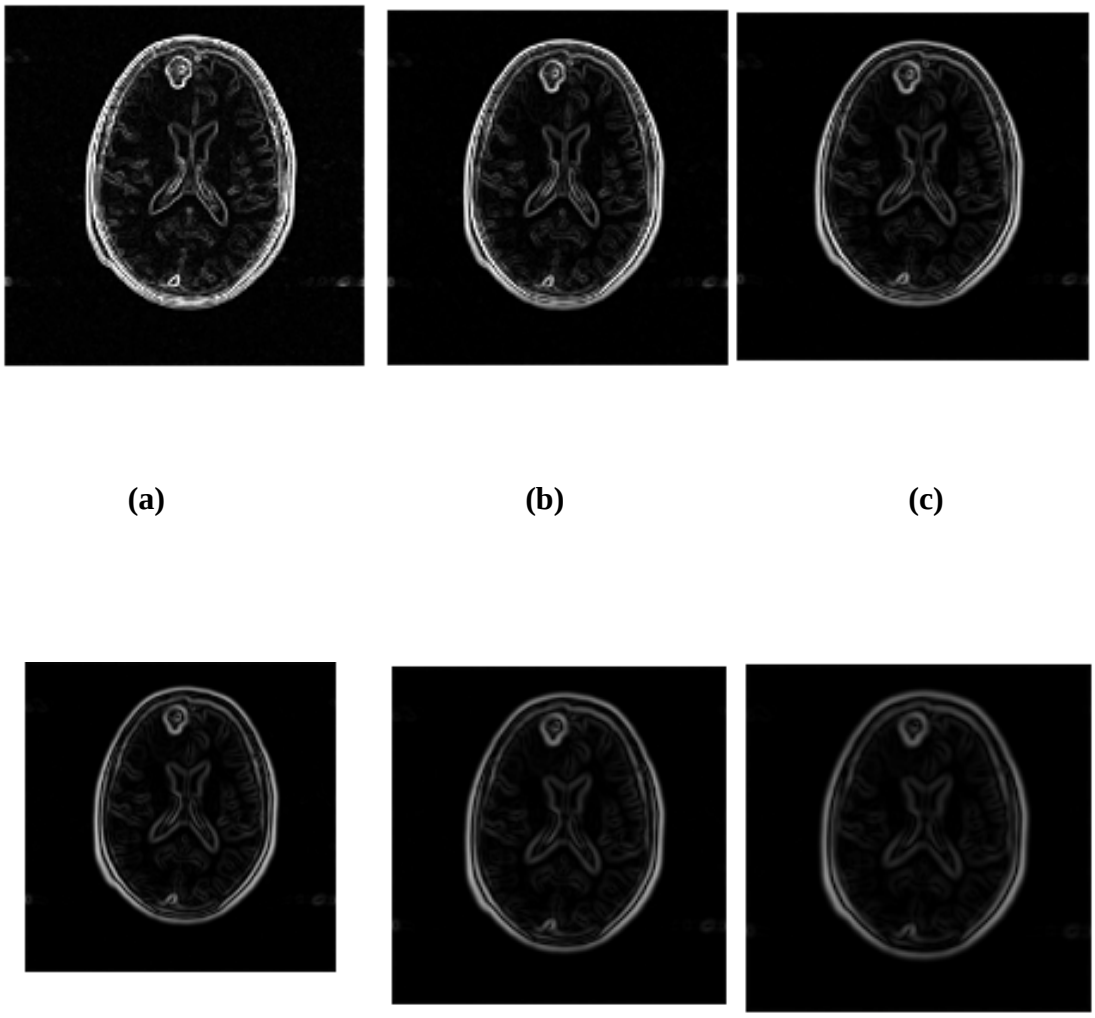

(a) **(b)** **(c)**

(d) **(e)** **(f)**

Figure.4.13. module du gradient en plusieurs échelles.

(a) module du gradient l’échelle1. **(b)** module du gradient à l’échelle 6. **(c)** module du gradient à l’échelle 10. **(d)** module du gradient à l’échelle 15. **(e)** module du gradient à l’échelle 20. **(f)** module du gradient à l’échelle 30

4.6.5 Orientations du gradient de l'image

Les cartes des orientations du gradient sont données par la figure4.14

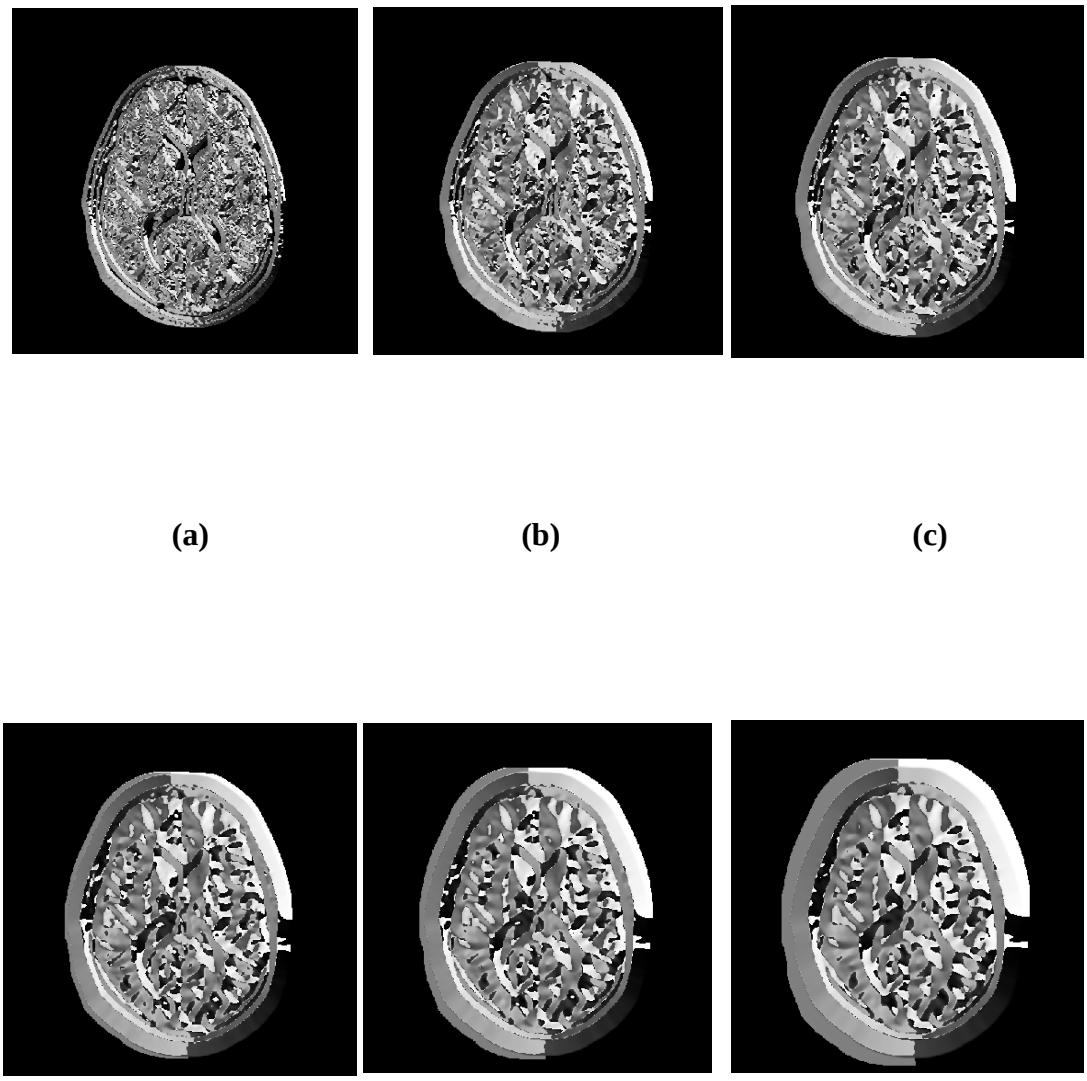

(a) **(b)** **(c)**

(d) **(e)** **(f)**

Figure.4.14.orientations en plusieurs échelles.

(a) orientations du gradient à l'échelle1**. (b)** orientations du gradient à l'échelle 6. **(c)** orientations du gradient à l'échelle 10.**(d)** orientations du gradient à l'échelle 15. **(e)** orientations du gradient à l'échelle 20. **(f)** orientations du gradient à l'échelle 30.

4.6.6. Maximas locaux

Les cartes de maxima locaux sont données par la figure4.15

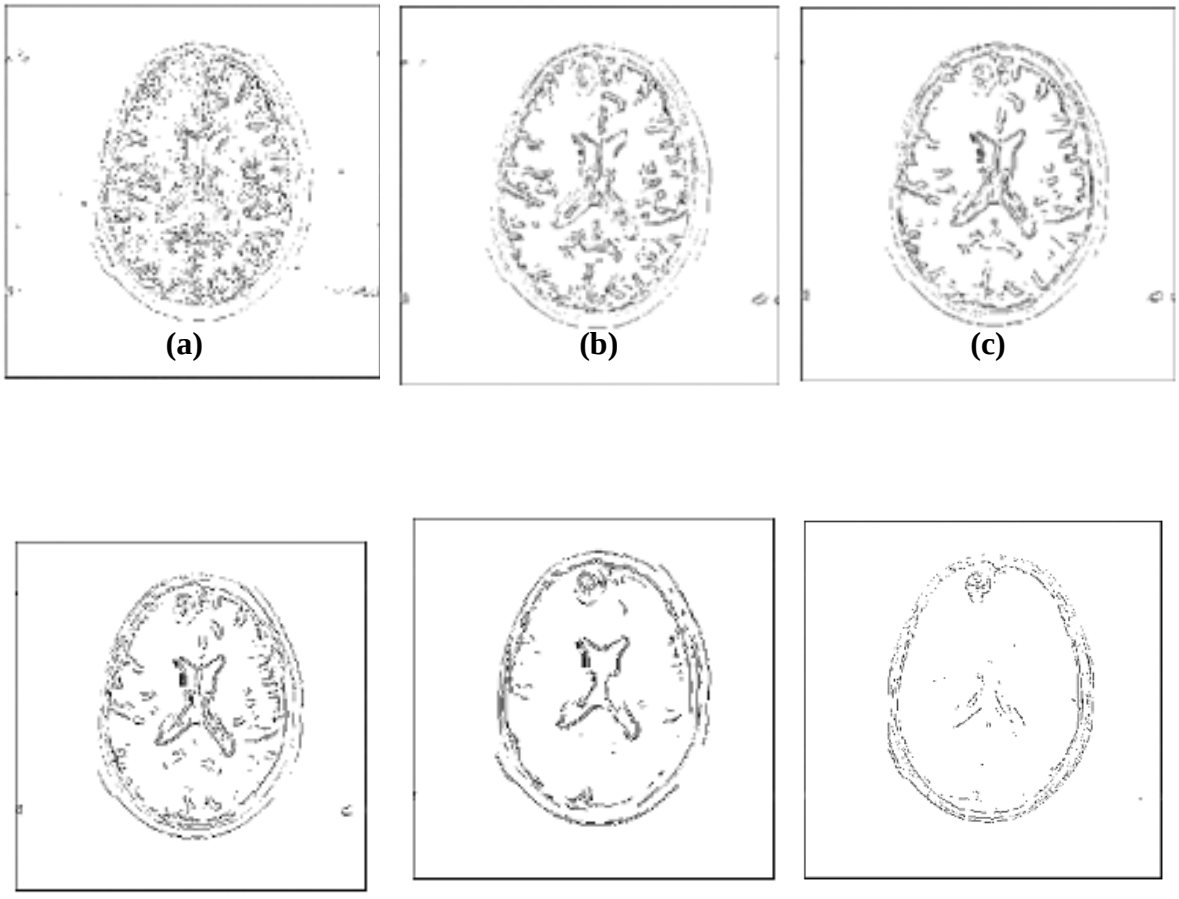

(a) **(b)** **(c)**

(d) **(e)** **(f)**

Figure.4.15. maximas locaux en plusieurs échelles.

(a) maximas locaux à l'échelle1. **(b)** maximas locaux à l'échelle 6. **(c)** maximas locaux à l'échelle 10. **(d)** maximas locaux à l'échelle 15. **(e)** maximas locaux à l'échelle 20. **(f)** maximas locaux à l'échelle 30.

4.6.7. Résultat après chainage

Le résultat après chainage est illustré par la figure4.16

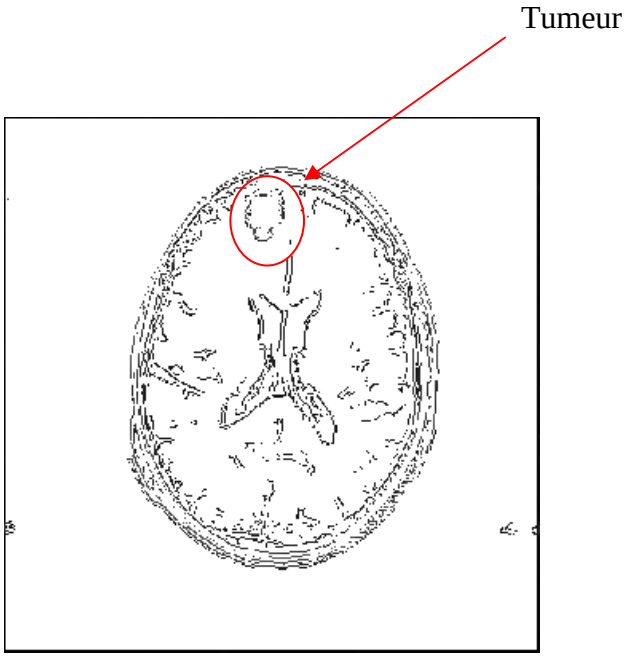

Fig.4.16. Résultat après chainage

4.6.8.Interprétation des resultats

Les résultats obtenus sur des images du cerveau atteint d'une tumeur sont semblables aux précédents pour la partie saine et mettent en évidence la tumeur pour la partie atteinte.

4.5.9.comparaison des résultatas obtenus avec l'approche de canny classique

Pour monter l'efficacité de la méthode une comparaison avec l'approche de canny classique a été réalisée.(voir figure.4.17).

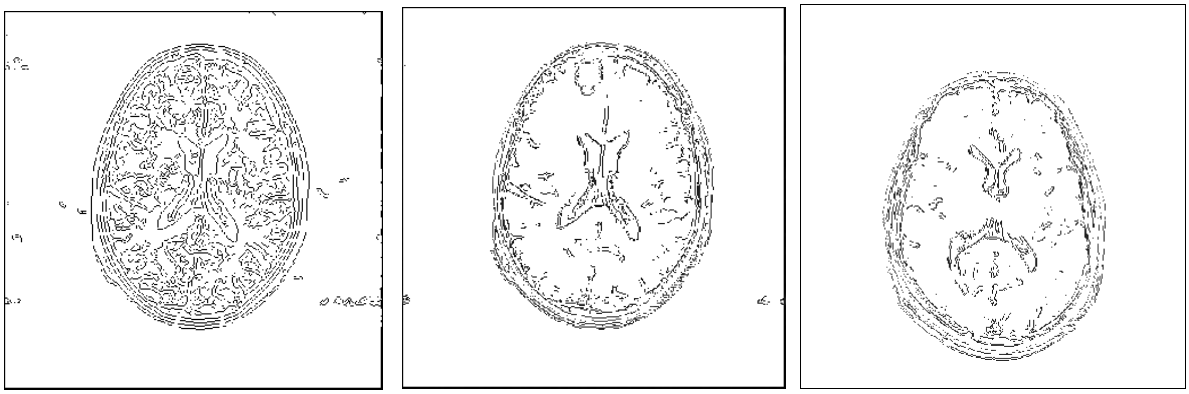

(a) **(b)** **(c)**

Figure.4.17.comparaison des differents resultats

(a) Resultat obtenu par l'applicaton de l'approche de canny classique.

(b) Resultat obtenu par l'application de notre méthode sur une image IRM d'un cerveau atteint d'une tumeur.

(c) Resultat obtenu par l'application de notre méthode sur une image IRM d'un cerveau sain.

En comparant les résultats obtenus, il parait nettement que notre methode donne de meilleurs resultats qu'avec l'approche de canny classique.

Avec notre technique nous pouvons distinguer la tumeur des differentes composantes du cerveau alors qu'avec l'approche de canny classique la tumeur n'est pas séparé des autres composantes du cerveau.

L'integration d'une information multi échelle rend l'approche de canny plus robuste, ce qui montre l'efficacité de notre méthode.

Conclusion

CONCLUSION

Le travail présenté dans ce mémoire a été réalisé dans le laboratoire d'analyse et de modélisation des phénomènes aléatoires (LAMPA).

Dans ce travail, nous avons élaboré une méthode de segmentation d'images IRM afin de détecter une tumeur cérébrale. Pour cela nous avons utilisé la technique du détecteur multi-échelles de canny.

Cette méthode est basée sur le calcul des maximas locaux qui sont obtenus par la combinaison du module et de l'orientation du gradient de l'image à base des coefficients d'ondelette à chaque échelle. Leurs chainage permet de retrouver les contours les plus significatifs.

L'avantage d'une telle méthode réside dans sa capacité à détecter les contours aux différentes échelles et à ne sauvegarder que les contours significatifs après chainage et ce sans réglage de paramètres au préalable.

L'application de notre méthode à deux images IRM représentant un cerveau sain et un autre atteint d'une tumeur a conduit à des résultats très significatifs. En effet, les différentes structures du cerveau ont été bien localisées dans les deux types d'images et la tumeur a bien été circonscrite dans l'image du cerveau atteint. Ces résultats montrent bien que la méthode élaborée est adaptée à ce type de traitement et pourrait être utilisée avantageusement en chirurgie et en radiothérapie. Il aurait aussi été intéressant d'appliquer cette technique sur d'autres pondérations et sur des images IRM 3D que nous n'avons malheureusement pas pu obtenir.

Malgré ces résultats significatifs cette méthode pourrait être améliorée en calculant par exemple la singularité lipschitzienne aux Point de contours. Concernant la détection des ruptures il serait intéressant de développer une méthode combinant l'approche région et l'approche contour pour affiner la localisation de la tumeur.

Bibliographie

BIBLIOGRAPHIE

[1] Sanae MIRI, 2007 : « Segmentation des structures cérébrales en IRM : intégration de contraintes topologiques », Rapport de stage, Master 2. Spécialité PARI, option IRMC Université Louis Pasteur, Strasbourg, France.

[2] GERMOND LAURENCE, 1999 : « Trois principes de coopération pour la segmentation en imagerie de résonance magnétique cérébrale », Thèse de doctorat, spécialité : Informatique, Université Joseph Fourier –Grenoble 1.France.

[3] Pierre-Yves Bondiau, 2004 : « Mise en œuvre et évaluation d'outils de fusion d'image en radiothérapie », Thèse de doctorat, spécialité : Informatique, Université de Nice-Sophia Antipolis. France.

[4] Philippe Chanson, 2001 :« recherche et santé », Revue « Fondation pour la Recherche Médicale ». N° 88, 4eme trimestre. *pp*.36-37.

[5] R.J. DEMEURE, 1999 : « Physique IRM-IRM d'aujourd'hui et de demain ».Rapport de stage de Master. Département de Radiologie UCL, Louvain Med, Belgique.

[6] Mme Weibei DOU, 2006 : « Segmentation d'images multi spectrales basée sur la fusion d'informations : application aux images IRM », Thèse de doctorat, Spécialité : Traitement du Signal et des Images, Université de CAEN, Basse-Normandie, France.

[7]Bernard Mazoyer, 2002 : « l'imagerie cérébrale : IRM et TEP ». Revue, Pour la science, N°302, *pp*.44-45.Decembre2002.

[8] Serge Langlois, Michel Desvignes, Jean Marc Constans et Marinette Revenu, 1997 : « Imagerie par résonance magnétique : correction des non linéarités des gradients de champ ». Seizième colloque GRETSI, 15-19 septembre 1997, Grenoble, France.

[9] Anne-Sophie Capelle, 2004 :« Segmentation d'images IRM multi-échos tridimensionnelles pour la détection des tumeurs cérébrales par la théorie de l'évidence ». Thèse de doctorat, Faculté des Sciences Fondamentales et Appliquées, Université de Poitiers. France.

[10] Jean- jacques Bard, Francis joffre, 2007 : « Contrôle de qualité spécifique en IRM : développement et réalisation d'un objet-test multimodal, évaluation des séquences IRM ». Rapport N°23, Institut Curie, Société française de physique médicale.

[11] haralick and shapiro, 1985 : Survey-image segmentation techniques, Computer Vision, graphics and image Processing ,vol 29.*pp*.100-132.

[12] cocquerez and philipp, 1995 : Analyse d'image :filtrage et segmentation, ed. Masson, Paris.France.

[13] Jérémy Lecoeur, Christian Barillot, 2008 : « Segmentation d'images cérébrales : État de l'art » rapport de recherche N°6306. INRIA, Université de Beaulieu, Rennes. France.

[14] T. N. Pappas, 1992 : « An adaptive clustering algorithm for image segmentation ». *IEEE Trans. Signal Proc.*, vol. 40, *pp*. 901–914.

[15] H.G. Schnack, H.E. Hulshoff Pol, W.F.C. Baare, M.A. Viergever, and R.S. Kahn, 2001: « Automatic Segmentation of the Ventricular System from MR Images of the Human Brain ». NeuroImage, vol.14. *pp*. 95–104.

[16] J.P. Thiran, V. Warscott, and B. Macq. 1997: « A queue-based region growing algorithm for accurate segmentation of multi-dimensional digital images ». Signal Processing, vol 10, N°60, *pp*.1–10.

[17] A. Hojjatoleslami and F. Kruggel, 2001: « Segmentation of large brain lesions ». IEEE Transactionson Medical Imaging, vol.20, N°7, *pp*.660–669.

[18] S. Warfield, J. Dengler, J. Zaers, C. Guttmann, W. Wells III, G.J. Ettinger, J. Hiller, and R. Kikinis, 1995: « Automatic Identification of Grey Matter Structures from MRI to Improve the Segmentation of White Matter Lesions ».The Journal of Image Guided Surgery,1(6):326–338.

[19] L. Kjaer, P. Ring, C. Thomsen, O. Henriksen, 1995: « Texture analysis in quantitative MR imaging.Tissue characterisation of normal brain and intracranial tumours ». Acta Radiol, vol. 36, N°2, *pp*. 127–135.

[20] S. Herlidou-Meme, JM. Constans, B. Carsin, D. Olivie, PA. Eliat, L. Nadal-Desbarats, C. Gondry, E. Le Rumeur, I. Idy-Peretti, JD. de Certaines, 2003 : « MRI texture analysis on texture test objects, normal brain and intracranial tumors ». Magnetic Resonance Imaging, vol. 21, N°9, *pp*. 989–993.

[21] Philippe Lamaty. Didier Demigny. Gérard Barbier, 1997: « Opérateur matériel de chaînage de contours temps réel et flot de données ».Seizième Colloque GRETSI — 15-19 septembre 1997 .Grenoble. France.

[22] Elise Arnaud, Edmond Boyer, 2000:« Analyse d'images : extraction de caractéristiques». Rapport de stage de master2. Option IHM. Université Joseph Fourier, INRIA Rhône-Alpes. France.

[23] Sauvaget Catherine Bourdin Jean-Jacques et Boyer Vincen, 2006 : « Rendus non photoréalistes : Traitements pixelaires, effet BD ». Journées de l'Association Francophone d'Informatique Graphique, Bordeaux.France.

[24] JOHN CANNY, 1986 : « A Computational Approach to Edge Detection ». IEEE transactions on Pattern Analysis and Machine Intelligence, vol. PAMI-8, N°6, *pp*. 679-697.

[25] Shu-Guang Liu, Ming-Yuan Liu, Yue He, 2008: Cardinal B-spline Wavelet Based on Canny's Edge Detection Criteria.Proceedings of the IEEE, International Conference on Wavelet Analysis and Pattern Recognition, Hong Kong.

[26] Zhang Shuqing, and Liu Songyan, Jin Mei and Su Lili, 2008 : "An Improved Canny Arithmetic Based on Image Pyramid Theories".Proceedings of the IEEE, International Conference on Automation and Logistics, Qingdao, China.

[27] Xujia Qin, Jionghui Jiang, Weihong Wang, Fan Zhang, 2007: "Canny Operator based Level Set Segmentation Algorithm for Medical Images".IEEE Trans. on Medical Imaging, vol. 6, N°3, *pp*.892-895.

[28] Xun Wang and Jian-Qiu Jin, 2007:"An Edge Detection Algorithm Based on Improved Canny Operator". IEEE Trans.on Image Processing, vol.3, N°2, *pp*.623-628.

[29] Mohamed Ali David Clausi, 2001: Using The Canny Edge Detector for Feature Extraction and Enhancement of Remote Sensing Images, IEEE.Trans on Image Processing, vol.5, N°3, *pp*.2298-2300.

[30] Stephane Mallat and Wen Liang Hwang, 1992 : "Singularity Detection and Processing with Wavelets". IEEE, Transactions on Information Theory, vol. 38, N° 2, *pp*.617-643.

[31] A. Cohen. Ondelettes et traitement numérique du signal. Masson, Paris, 1992.

[32] I.Daubechies, 1989: « The wavelet transform, time-frequency localization and signal analysis ».IEEE. Transactions on Information Theory, vol. 10, N° 4, *pp*.202-233.

[33] Lucas Quarta, 2001:« Une introduction (élémentaire) à la théorie des ondelettes ».rapport de stage, Institut de Mathématique, Université de Mons-Hainaut, Belgique.

[34] I. Bloch, Y. Gousseau, H. Maître, D. Matignon, B. Pesquet-Popescu, F. Schmitt, M. Sigelle, F. Tupin, 2004 : « Le traitement des images », tome 1, Département TSI - Télécom-Paris, version 5.0.

[35] S.G. Mallat, 1989: « A thory for multiresolution signal decomposition: The wavelet representation ». IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 11, N°.7, *pp*. 674-693.

[36] Victor Racine, 2003 : « Traitement des données générées par vidéo-microscopie 4D (3D+t) pour l'analyse de l'implication des protéines Rab6A et Rab6A dans le transport vésiculaire ». Thése de DEA, Institut Curie. France.

[37] Ahmed Ben Atitallah, Mohamed Ali Ben Ayed, Mourad Loulou, Nouri Masmoudi : « Implémentation électronique de la transformée en ondelette discrète unidimensionnelle ». Laboratoire d'Electronique et des Technologies de l'Information (LETI), Ecole National d'Ingénieurs de Sfax, Tunisie.

[38]Fred Truchetet, 1998 : « Ondelettes pour le signal numérique », Editions Hermes, Paris.

[39]Perre Gilles Lemarié-Rieusset ,1992: « sur l'existence des analyses multi résolutions en théorie des ondelettes ». Revista Mat. Ibroamericana. Vol 8, N°3, *pp*.333-370.

[40]Saber Mezghani, 2005 : « Approches multi-échelles de caractérisation tridimensionnelle des surfaces, Applications aux procédés d'usinage ». Thèse Doctorat, Spécialité : Mécanique, école Centrale de Lyon. France.

[41]S. Journaux, P. Gouton, M. Paindavoine, G. Thauvin, 2001 : « Extraction des joints de grains par ondelettes directionnelles et morphologie mathématique : application à l'évaluation de l'endommagement par fluage ». Revue de Métallurgie-CIT/Science et Génie des Matériaux. *pp*.485-498.

[42] M. J. Shensa, 1992: « The Discrete Wavelet Transform: Wedding the A Trous and Mallat Algorithms », IEEE Transactions on Signal Processing, vol. 40, *pp* 2464-2482.

[43] Hela Mahersia Sahbani, Kamel Hamrouni, Noureddine Ellouze, 2007 : « Identification de texture par fusion d'attributs multi-résolutionnels et invariants à la rotation ». Ecole Nationale d'Ingénieurs de Tunis (ENIT), 4th International Conference: Sciences of Electronic, Technologies of Information and Télécommunications, Tunisie.

[44] Bijaoui, Jean-Luc Starck, Fionn Murtagh, 1994 : « Restauration des images multi-échelles par l'algorithme à trous », Traitement du Signal. Vol 11, N° 3. *pp*.230-243.

[45]Valérie Perrier ,2005 : « Application de la théorie des ondelettes ». Enseignement Unesco, ENIT, Traitement du signal et des images numériques, Tunis.

[46] Canny J, 1986: "A computational approach to edge detection". IEEE Transaction on pattern analysis and machine intelligence, Vol 8, N°6, *pp*. 679-698.

[47] Philippe Carré, 2004 :« Maxima d'ondelettes couleur ». N° spécial, l'image numérique couleur. Traitement du signal, volume 21, *pp*.623-633.

[48] Grégoire Mercier, Stéphane Derrode, Wojciech Pieczynski, 2004 :« Segmentation multiéchelle de nappes d'hydrocarbure ». Traitement du signal 2004, vol 21, N° 4.*pp.*329-344.

[49] Jie Hou, Jin-Hua Ye, Sha-Sha Li, 2007: "Application of Canny Combining and Wavelet Transform in The Bound of Step-Structure Edge Detection". IEEE. Proceedings of the 2007 International Conference on Wavelet Analysis and Pattern Recognition, Beijing, China.

[50] Stephane Mallat, and Sifen Zhong, 1992: "Characterization of Simals from Multiscale Edges". IEEE, Transactions on Patiern analysis and machine intelligence, vol.14, N° 7, *pp.*674-693.

[51] Guo Fude Yang Yahui Ning Tao Chen Bin Guo Lieijin, 2008: "Edge Detection Based on Wavelet Analysis with Gaussian Filter". IEEE, Congress on Image and Signal Processing. *pp.*724-728.

[52] Yu-Ping Wang and S.L. Lee, 1998 : "Scale-Space Derived From B-Splines". IEEE Transactions on pattern analysis and machine intelligence, Vol 20, N° 10, *pp.*1040-1054.

[53] Christophe Damerval, 2007 : « Notes sur la régularité Lipschitzienne » LJK, Grenoble.

[54] Rym Besrour, Zied Lachiri et Noureddine Ellouze, 2007 : « Détection de l'Onde R d'un Electrocardiogramme Basée sur le Produit Multiéchelle », 4rth International Conférence, Sciences of Electronic, Technologies of Information and Télécommunications, Tunisie.

[55] Enguerran Grandchamp, 1998 : « Outils d'aide à la segmentation d'image : classification de ruptures par décomposition en ondelettes », INP-ENSEEIHT.

[56] F. Bloch. Nuclear induction. In Physical Review, pages 460–474, 1946.