



Université A.MIRA de Bejaia
Faculté de la Technologie
Département génie électrique

MEMOIRE

En vue d'obtention du Diplôme de Master

Spécialité : Télécommunication
Option : Réseaux et Télécommunication

Thème

Segmentation d'images par classification de pixel:
Application aux images IRM.

Présenté par :

Melle ACHOUR Nadine.

Melle DROUCHE Tassadit.

Sous la direction de Mr : MEKHEMOUKH Abdenour.

Soutenue publiquement le 26/06/2018
devant le jury composé de :

Mr. ALLICHE.A
Mme .GHENAME.S

Président du jury
Examinatrice du jury

Remerciements

Louange à notre Seigneur "ALLAH" qui nous a doté de la force, de la santé, de la volonté, du courage et patience qui nous ont été utiles tout le long de notre parcours. Louange à notre créateur qui nous a incité à acquérir le savoir.

Nous exprimons notre profonde gratitude à notre encadreur Mr MEKHMOUKH Abdenour, ce fut une grande fierté et un honneur pour nous de travailler sous la houlette d'un homme pour lequel nous avons une grande admiration, nous le remercions pour son aide, sa disponibilité, sa gentillesse et ces précieux conseils.

Nous exprimons aussi nos vifs remerciements à tous les enseignants du département ATÉ qui nous ont permis d'acquérir des connaissances dans le domaine des télécommunications durant notre cursus ainsi qu'aux membres de jury qui ont accepté de juger et d'examiner ce présent travail.

Enfin nous remercions tous ceux qui ont contribué de près ou de loin à l'aboutissement de ce travail.

Nadine et Tassadit.

Dédicaces

C'est avec toute l'ardeur de mes sentiments que je dédie ce modeste travail qui est le fruit de ma profonde reconnaissance à :

Mon père et Ma mère qui m'ont fournis au quotidien un soutien et qui peuvent être fiers et trouver ici le résultat de longues années de sacrifices et privations pour m'aider à rendre mes rêves réalité, que dieu les gardes et les protèges.

Mon cher frère Yanis qui a toujours été un frère et un ami pour moi.

À mes deux chères petites cousines jumelles Alicia & Anélya, qui me rend le sourire et me redonne la force lorsque je me retrouve dans des situations délicates.

À ma grande famille.

À ma binôme Tassadit avec qui j'ai partagé des bons et des mauvais moments.

Tous mes ami(e)s de l'Université et d'ailleurs

Tous mes enseignants de la première année jusqu'à aujourd'hui.

Toute personne que j'aime et qui est chère chez moi.

Et à ceux qui ont cru en moi.

Nadine.

Dédicaces

Je dédie ce modeste travail

À la mémoire de mon père qui me conseillait et me poussait vers le but le plus sublime dans la vie.

À ma mère pour l'éducation qu'elle m'a prodiguée, et pour son affection et son sacrifice.

À mon cher frère Makhlouf, et ma chère sœur Sabah pour leurs encouragements.

À ma binôme et amie Nadine et sa famille.

À tous mes amis avec lesquels j'ai partagé mes moments de joie et de bonheur, et à tous ceux qui me sont chers.

Enfin à tous ceux qui ont de près et de loin m'ont accordé leur soutien moral et physique pour la réalisation de ce projet.

Tassadit.

Sommaire

Liste des figures	i
Liste des algorithmes	iii
Liste des tableaux.....	iv
Liste des abréviations.....	v
Introduction générale	01
Chapitre I : Généralités sur le traitement d'images	
Introduction	03
I.1. Notions de base sur le traitement d'images.....	04
I.1.1 L'image	04
I.1.2 L'analyse d'images.....	06
I.1.2.1 Rehaussement d'image.....	07
I.1.2.2 Segmentation d'image	07
I.2. Les bases de la segmentation.....	08
I.2.1 Segmentation à base de contour.....	09
I.2.2 Segmentation à base de région.....	09
I.2.3 Segmentation par classification	10
I.2.3.1 Méthodes de la classification	10
1) Méthode supervisée	11
2) Méthode non supervisée	11
I.2.3.2 Algorithme des K-means	15
I.3 Conclusion.....	15
Chapitre II : Segmentation par l'algorithme des Fuzzy C-Means	
Introduction.....	16
Partie 1 : Les Fuzzy C-Means et ses variantes	
II.1. Algorithme des Fuzzy C-means standard (FCM).....	17
II.1.1 Notations.....	17
II.1.2 Algorithme 2 : Algorithme général d'exécution du FCM.....	18

II.1.3	La différence entre fuzzy C-Means et k-Means	19
II.1.4	Avantages et inconvénients de l'algorithme (FCM).....	19
II.2.	Les C-moyennes floues avec contraintes spatiales FCM_S	20
II.2.1	L'algorithme FCM-S1	21
II.2.2	L'algorithme FCM-S2.....	22
II.2.3	L'algorithme d'exécution des FCM-S1 et FCM-S2	22
II.2.4	Avantages et inconvénients du FCM-S	23
II.3	FCM régularisé adaptatif avec fonction noyau (ARKFCM)	23
II.3.1	Algorithme d'exécution du ARKFCM.....	25
Partie 2 : Tests des différents algorithmes sur des images IRM		
II.4	Imagerie par résonance magnétique (IRM)	26
II.5	Anatomie cérébrale.....	26
II.5.1	Le cerveau.....	26
II.5.1.1	La matière blanche (MB)	27
II.5.1.2	La matière grise (MG).....	27
II.5.1.3	Le liquide céphalo-rachidien (LCR).....	27
II.5.2	Lésions cérébrales.....	27
II.5.2.1	Tumeur cérébrale.....	28
II.6	Artefacts des images IRM.....	29
II.6.1	Le mouvement	29
II.6.2	Variations du champ magnétique.....	29
II.6.3	Le bruit.....	29
II.7.	Segmentation d'une image IRM sans bruit	30
II.8.	Segmentation d'une image IRM en présence d'un bruit	33
II.9	Conclusion.....	41

Chapitre III : Détection et classification d'une tumeur cérébrale

Introduction	42
III.1. Processus de classification de la tumeur	43
III.1.1 Base de données utilisées	43
III.1.2 Opérations morphologiques.....	44
III.1.3 Segmentation par ARKFCM	45

III.1.4	Extraction des caractéristiques	46
III.1.4.1	Transformée en ondelettes discrète	47
III.1.4.2	Analyse en Composantes Principales (PCA)	49
III.1.4.3	Matrice de cooccurrence	49
III.1.4.4	Phase de classification par SVM (Support Vector Machines)	52
III.2	Résultats et discussion	53
III.3	Conclusion	57
	Conclusion Générale	58
	Bibliographie.	

Liste des figures

Figure I.1: Image numérique.....	04
Figure I.2: Illustration d'un pixel.	05
Figure I.3: Une image avec son histogramme.	05
Figure I.4 : Etapes du processus d'analyse d'images.	06
Figure I.5 : Réduction de bruit et rehaussement de contraste par filtrage.	07
Figure I.6 : Exemple de segmentation par approche contour.	09
Figure I.7 : Exemple de segmentation par approche région.	10
Figure I.8: (a)- Classification nette (b)- Classification floue.....	12
Figure I.9 : Principe de fonctionnement général de K-Means.....	13
Figure I.10 : Démonstration des quatre étapes de K-Means avec (K=3).....	13
Figure I.11 : Exemple de classification par K-Means..	14
Figure II.1 : Fonction d'appartenance d'un nuage de points avec les deux algorithmes K-Means et FCM.	19
Figure II.2 : Cerveau humain composé des substances.	27
Figure II.3 : Image IRM normale et en présence d'une tumeur.	28
Figure II.4 : Image médicale originale.....	30
Figure II.5 : Résultat de la segmentation par les K-Means.....	30
Figure II.6 : Résultat de la segmentation par les FCM.	31
Figure II.7 : Résultat de la segmentation par les FCM_S1.....	31
Figure II.8 : Résultat de la segmentation par les FCM_S2.....	32
Figure II.9 : Résultat de la segmentation par ARKFCM.S.....	32
Figure II.10 : Résultat de la segmentation par les K-means d'une image bruitée avec Salt & Pepper.	33
Figure II.11 : Résultat de la segmentation par les FCM d'une image bruitée avec Salt & Pepper.	34
Figure II.12 : Résultat de la segmentation par les FCM-S1 d'une image bruitée avec Salt & Pepper.	34
Figure II.13 : Résultat de la segmentation par les FCM-S2 d'une image bruitée avec Salt & Pepper.	35

Figure II.14 : Résultat de la segmentation par ARKFCM d'une image bruitée avec Salt & Pepper.	35
Figure II.15: Résultat de la segmentation par les K-Means d'une image avec un bruit Gaussien	36
Figure II.16 : Résultat de la segmentation par le FCM d'une image avec un bruit Gaussien.	37
Figure II.17 : Résultat de la segmentation par le FCM-S1 d'une image avec un bruit Gaussien	37
Figure II.18 : Résultat de la segmentation par le FCM-S2 d'une image avec un bruit Gaussien	38
Figure II.19 : Résultat de la segmentation par ARKFCM d'une image avec un bruit Gaussien.	38
Figure II.20 : Evaluation des performances des différents algorithmes (Indice de Jaccard)	40
Figure II.21 : Evaluation des performances des différents algorithmes (Indice de Dice).	41
Figure III.1 : Processus de classification.	43
Figure III.2 : Principe de fonctionnement des opérations morphologiques.....	44
Figure III.3 : érosion (gauche) et dilatation (droite) de l'objet binaire en utilisant un élément structurant B circulaire.	45
Figure III.4: Image avec tumeur et le résultat de segmentation par ARKFCM.	45
Figure III.5: Résultat de la segmentation classe par classe.....	46
Figure III.6: Résultat de l'opération morphologique sur la tumeur.	46
Figure III.7 : Processus d'extraction des caractéristiques de la tumeur.	47
Figure III.8 : Arbre de décomposition niveau 3.....	49
Figure III.9 : Transformée en ondelettes discrète s'applique à une image.....	49
Figure III.10 : Transformation d'une image à GLCM. (a) : Image (b) : Son GLCM.	49
Figure III.11: L'interpolation géométrique des SVM linéaires (H désigne l'hyperplan, S désigne le vecteur de support).	53
Figure III.12 : Phase de classification de la tumeur par les SVM.	53

Liste des algorithmes

1. Algorithme des K-means.....	13
2. Algorithme d'exécution du FCM.....	18
3. L'algorithme d'exécution des FCM-S1 et FCM-S2.....	22
4. Algorithme d'exécution du ARKFCM	25

Liste des tableaux

Tableau II.1 : Résultats obtenus pour les cinq algorithmes K-Means, FCM, FCM-S1, FCM-S2, ARKFCM sans bruit et avec bruit. (Indice de Jaccard).....	39
Tableau II.2 : Résultats obtenus pour les cinq algorithmes K-Means, FCM, FCM-S1, FCM-S2, ARKFCM sans bruit et avec bruit. (Indice de Dice).	40
Tableau III.1 : Résultats de la classification des tumeurs présentes dans les images IRM.	56
Tableau III.2 : Taux de classification	57

Liste des abréviations

RGB : Red Green Blue.

PPV : Plus Proches Voisins.

IRM : Imagerie par Résonance Magnétique.

ARKFCM : Adaptively Regularized Kernel-Based Fuzzy *C*-Means.

FCM : Fuzzy *C*-Means.

MB : Matière Blanche.

MG : Matière Grise.

LCR: Liquide Céphalo-Rachidien.

LVC : Local Variation Coefficient.

RMN : Résonance Magnétique Nucléaire.

PCA : Principale Component Analysis.

Dwt : Discrete Wavelet Transform.

SVM : Support Vector Machines.

GLCM : Gray Level Co-occurrence Matrix.

RMS : Root Mean Square.

IDM : Inverse Difference Moment.

Introduction Générale

Le traitement d'images est un domaine très vaste qui a connu, et qui connaît encore, un développement important depuis quelques dizaines d'années.

On désigne par traitement d'images numériques l'ensemble des techniques permettant de modifier une image numérique afin d'améliorer ou d'en extraire des informations.

Afin d'extraire des informations pertinentes qui aident un médecin dans ses choix thérapeutiques pour mettre fin à l'évolution des pathologies cérébrales, la segmentation d'images médicales est une étape essentielle dans un processus d'interprétation d'images du cerveau humain, issues de différentes modalités d'imagerie (imagerie par résonance magnétique IRM, scanner...). Cette dernière permet de séparer les différentes régions qui composent l'image cérébrale (matières grise, matière blanche, liquide céphalorachidien, lésion). En effet, nous pouvons repérer sur ces images la présence d'anomalies ce qui permet de détecter certaines maladies. Par exemple, la détection d'une tumeur dans le cerveau du patient.

Une fois, la segmentation de l'image IRM est effectuée et toutes les régions (classes) qui la composent identifiées et après avoir sélectionné la région d'intérêt qui est dans notre cas une tumeur au niveau du cerveau, une autre étape importante doit être accomplie dans le but de réaliser une classification de la tumeur en question.

L'objectif que nous fixons dans notre travail, est depuis une image réelle IRM quelle est la bonne méthode de segmentation qui permet d'isoler la partie tumorale ? Et comment arriver à se prononcer sur la tumeur en la classifiant en **tumeur bénigne** ou **tumeur maligne**.

En effet, nous utilisons des techniques de classification de pixels basées sur la logique floue (algorithme des Fuzzy C-Means et ses variantes) pour résoudre la problématique que nous avons fixée.

Ce manuscrit s'articule au tour de trois chapitres :

- Dans le premier chapitre, nous abordons les notions de base nécessaires à la compréhension des techniques de traitement d'images. Ensuite, nous allons donner un bref aperçu sur les différentes techniques de segmentation connues dans ce domaine.

- Dans le deuxième chapitre, nous allons d'une part détailler l'algorithme de base de segmentation par classification de pixels qui repose sur les concepts de la logique Fuzzy C-Means (FCM) et d'autre part, nous allons présenter les résultats expérimentaux obtenus sur des images IRM réelles après l'application des différentes variantes du FCM (FCM-S, ARKFCM).
- Dans le dernier chapitre, nous allons appliquer la méthode ARKFCM sur des images IRM du cerveau contenant une tumeur en vue d'une classification de cette dernière en deux classes : tumeur **bénigne** ou **maligne**.

Enfin, notre travail s'achève par une conclusion générale et quelques perspectives pour les travaux à venir.

Le présent chapitre est organisé en deux parties :

- Notions de base, dans lequel nous allons voir la définition de l'image qui correspond au support sur lequel nous avons travaillé. Ensuite nous allons brièvement discuter sur les différentes phases d'un processus de traitement d'image tels que le rehaussement et la segmentation d'image.
 - Les bases de segmentation, cette partie sera consacrée aux différentes méthodes de segmentation existantes à savoir la segmentation à base de contours, à base de régions, et par classification, et leurs différentes variantes.
-

I.1 Notions de base sur le traitement d'images

I.1.1 L'image

Le mot image, du latin imago (représentation, portrait, copie), désigne la représentation visuelle d'un objet [1] par différents moyens ou supports, le dessin, la peinture, la sculpture, la photographie, le film...etc. C'est aussi un ensemble structuré d'informations qui, après l'affichage sur l'écran, ont une signification pour l'œil humain.

Elle peut être décrite sous la forme d'une fonction $i(x,y)$ brillance analogique continue, définie dans un domaine borné, tel que x et y sont les coordonnées spatiales d'un point de l'image et i est une fonction d'intensité lumineuse et de couleur. Sous cet aspect, l'image est inexploitable par la machine, ce qui nécessite sa numérisation [2].

La numérisation est le processus qui permet de passer de l'état d'image physique qui est caractérisé par l'aspect continu du signal qu'elle représente, à l'état d'image numérique qui est caractérisé par l'aspect discret. C'est cette forme numérique qui permet une exploitation ultérieure par des outils logiciels sur ordinateur et qu'on appelle une image numérique. Cette dernière est constituée de zones rectangulaires comme on peut le voir ci-dessous

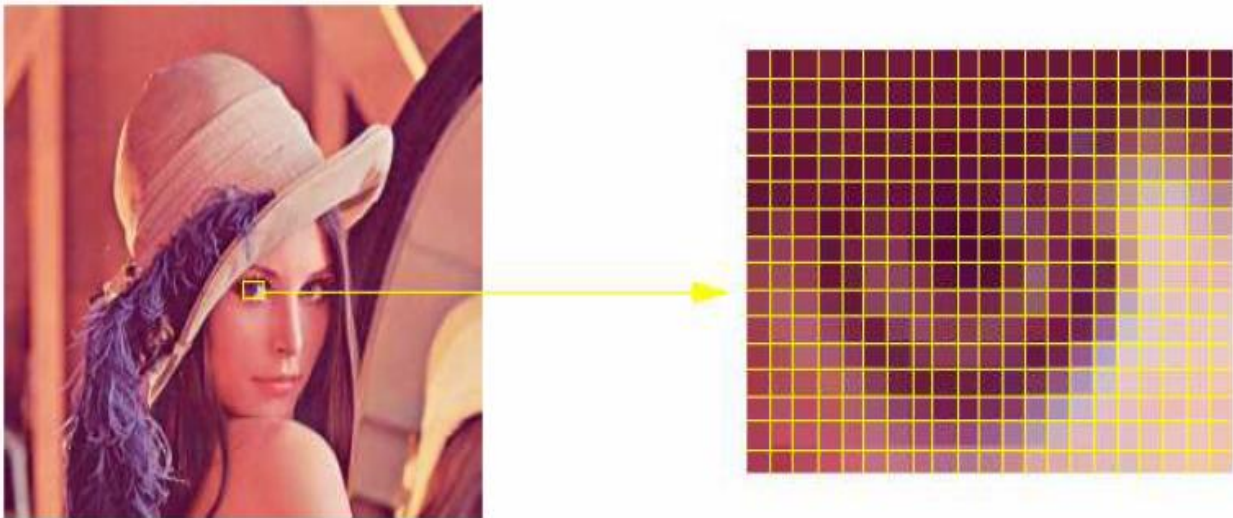


Figure I.1: Image numérique

Ici, après un zoom sur une partie de l'image (l'œil), on peut voir cette composition de l'image en zones rectangulaires appelées des pixels.

- **Le pixel**

Le nom de "pixel", provient de l'expression anglaise "Picture element", qui signifie "élément d'image" ou "point élémentaire".

Le pixel est l'unité de base et le plus petit élément constitutif d'une image numérique, Il constitue l'unité minimale adressable par le contrôleur vidéo. A chaque pixel est associée une couleur, elle-même décomposée en 3 composantes primaires qui sont le Rouge, le Vert et le Bleu (RGB).

Les pixels ont une forme rectangulaire proche du carré comme le montre la figure suivante :




Figure I.2: Illustration d'un pixel.

Ici, la couleur associée est le vert et on voit bien la forme rectangulaire voire carrée de cet élément de base d'une image numérique.

- **L'histogramme d'une image**

L'histogramme des niveaux de gris ou des couleurs d'une image est un graphique sous la forme d'une courbe qui met en valeur la répartition des pixels d'une image selon leur luminosité offrant ainsi une visualisation de l'exposition d'une photo. Un simple exemple est représenté sur la figure I.3 [3].

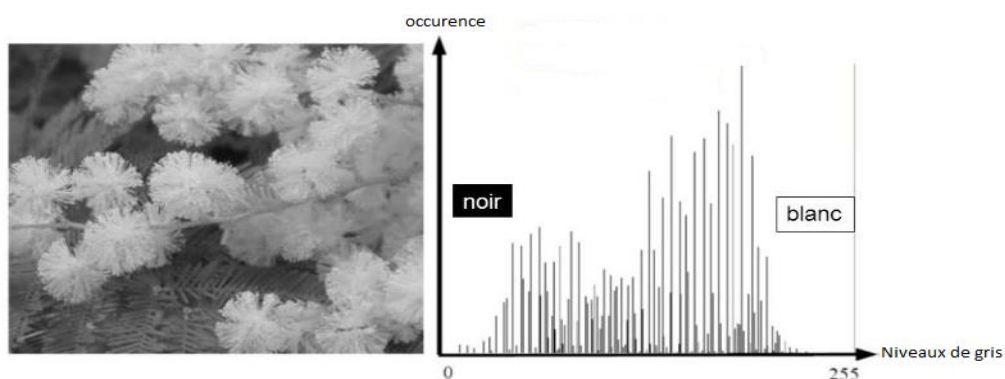


Figure I.3: Une image avec son histogramme.

I.1.2 L'analyse d'images

Le processus d'analyse d'images a pour but de fournir une description ou une interprétation d'une scène à partir de l'information extraite de l'image. Il peut être décomposé en plusieurs étapes, comme le montre la figure suivante (figure I.4).




Figure I.4 : Etapes du processus d'analyse d'images.

Le premier procédé dans ce système est l'acquisition d'une scène comme le montre la figure I.4 cette étape consiste à discrétiser l'image réelle afin d'être traité par l'ordinateur. Cette opération entraîne une perte d'informations et par delà une dégradation de la qualité d'image. De ce fait l'image doit passer par un prétraitement afin de restaurer les informations dégradées lors de la phase d'acquisition et obtenir une image plus nette que possible. Dans cette étape les détails de l'image peuvent être rehaussés par plusieurs techniques.

Après rehaussement de l'image, vient l'étape de segmentation qui est une opération de bas niveau et qui joue un rôle fondamentale. Elle a pour but de partitionner une image en régions ou à détecter leurs frontières.


Cette étape est la plus importante elle doit être performante car c'est de la qualité de son résultat que dépendent les autres opérations dites de haut niveau telle que la décision et la description de l'image. Nous allons détailler par la suite cette étape.

Ensuite, viennent les traitements de haut niveau, telles que la description de l'image, la reconnaissance des formes et les décisions qui pourront être prises à partir des résultats fournis par la segmentation.


I.1.2.1 Rehaussement d'image

Le rehaussement d'image a pour but d'améliorer l'apparence et la qualité de l'image, par la suppression des bruits présents sur elle, et de faire ressortir quelques structures d'intérêts présentes sur cette dernière, pour faciliter l'interprétation visuelle et la compréhension des images.

Le rehaussement est réalisé par des filtres appliqués sur une image pour la transformer vers une autre image plus claire, comme le montre l'exemple ci-dessous :



(a) Image initiale



(b) image rehaussée

Figure I.5 : Réduction de bruit et rehaussement de contraste par filtrage.

I.1.2.2 Segmentation d'image

- **Définition**

La segmentation d'image joue un rôle prépondérant dans le traitement d'image et dans une variété d'applications telles que la médecine, la géologie, la biométrie et la bureautique.

C'est une étape importante pour l'extraction des informations qualitatives de l'image. Elle consiste à découper une image en régions connexes présentant une homogénéité selon un certain critère, comme par exemple les critères de texture et/ou de couleur. Les régions obtenues se distinguent les unes des autres par des différences significatives selon ces mêmes critères, l'union de ces dernières doit redonner l'image initiale.

Chapitre I: Généralités sur le traitement d'images

De façon plus précise, on peut définir la segmentation comme étant une partition d'une image I en n ensembles R_i appelés régions qui sont homogènes par rapport à un prédicat donné :

$$\begin{cases} \forall i, R_i \neq \emptyset \\ \forall i, j, i \neq j, R_i \cap R_j = \emptyset \\ I = \cup R_i \end{cases} \quad (1.1)$$

Les régions R_i doivent être disjointes et celles qui sont adjacentes doivent être hétérogènes [4].

Le choix d'une technique de la segmentation est liée à plusieurs facteurs comme : la nature de l'image, les conditions d'acquisition (bruit), les primitives à extraire (contours, objets, textures, formes, régions).

- **Objectif [3]**

- ✓ L'extraction d'éléments et d'informations qualitatives de l'image.
- ✓ Fournir des régions homogènes.
- ✓ Localiser les contours de région.
- ✓ Réduire le bruit.

I.2 Les bases de la segmentation

L'étape de segmentation doit transformer l'image en une information, quantitativement, réduite et/ou, qualitativement, rehaussée. Cette transformation est confrontée aux problèmes d'ambiguïtés et du bruit qui affectent certains pixels de l'image [4]. Pour cela, plusieurs techniques de segmentation d'images ont vues le jour.

Ces techniques de segmentation peuvent être classées en trois grandes approches :

1. Les approches frontières (contour) ;
2. Les approches régions ;
3. Les approches de types classification ;

I.2.1 Segmentation à base de contour

Appelé aussi approche frontière, cette méthode s'intéresse aux informations sur les contours des différents objets dans l'image, elle effectue un balayage de l'image pour rechercher et identifier les contours. Donc un contour est un ensemble de pixels qui séparent deux régions voisines homogènes, ces pixels forment une frontière [5].

Plusieurs méthodes utilisant l'approche contours ont été proposées dans la littérature, comme les méthodes dérivatives qui utilisent le Gradient ou le Laplacien pour obtenir des informations sur les contours de l'image. Y a aussi les méthodes par morphologie mathématique et les méthodes par modèles déformables.

Mais ce genre de techniques est peu utilisable car il donne souvent des contours non fermés, bruités ou non détectés. Pour éviter ce type d'inconvénients. Il faut donc utiliser des techniques de reconstruction de contours par interpolation ou connaître a priori la forme de l'objet recherché.

La figure suivante (figure I.6) montre un exemple d'une image segmentée par cette méthode :

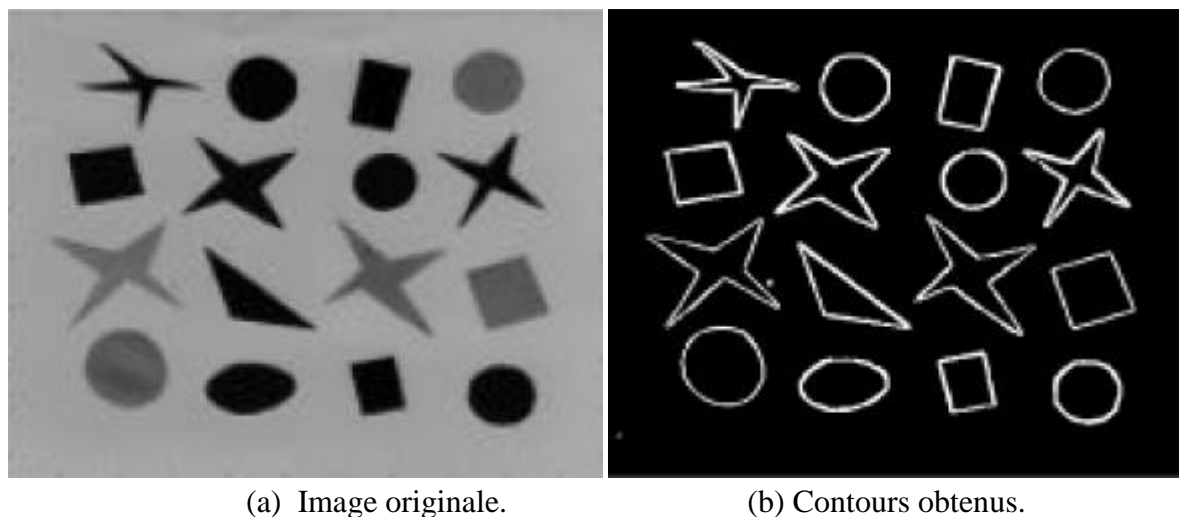



Figure I.6 : Exemple de segmentation par approche contour.

I.2.2 Segmentation à base de région

Contrairement à la segmentation par contours, la segmentation en régions consiste à décomposer l'image en des régions homogènes. Une région est composée de l'ensemble des pixels connexes possédant des propriétés communes.

Différentes approches ont été proposées dans la littérature comme celles basées sur le seuillage, la croissance de régions. Le mean-shift, la classification etc.



(a) Image originale.

(b) Image segmentée.

Figure I.7 : Exemple de segmentation par approche région.

I.2.3 Segmentation par classification

Cette méthode consiste à regrouper et à classer les pixels d'une image en classes en fonction de leurs propriétés. A chaque point de l'image est associé un vecteur d'attributs. La classification est alors effectuée sur ces vecteurs d'attributs de façon à aboutir à un nombre restreint de régions homogènes au sein de l'image

Donc cette dernière est définie comme une procédure dans laquelle les pixels similaires d'une image sont identifiés et regroupés dans une même classe. Il existe deux grandes tendances : la classification supervisée, basée sur l'apprentissage de propriétés discriminantes sur un échantillon de données déjà classées, et la classification non supervisée basée sur une mesure de distance entre les vecteurs d'attributs.

I.2.3.1 Méthodes de la classification

De nombreuses méthodes de classification ont été consacrées, elles peuvent être séparées en deux grandes catégories : les méthodes de classification supervisée ou classification avec apprentissage et les méthodes de classification non supervisée :

1) Méthode supervisée

Les méthodes de classification supervisée supposent la connaissance a priori de l'appartenance de chaque échantillon de l'ensemble d'apprentissage à une classe donnée, [5] ce qui revient à supposer une connaissance a priori sur l'image à segmenter.

Parmi les méthodes de cette catégorie nous pouvons donc citer celui de Bayes, Les K plus proches voisins (K-PPV) ou les réseaux de Neurones Multicouches.

2) Méthode non supervisée

Cette classification est aussi appelée "classification automatique", "clustering" ou encore "regroupement". Cette méthode à l'inverse des méthodes de classification supervisée, vise à séparer automatiquement l'image en clusters sans aucune connaissance a priori sur les classes. Elle se base sur une mesure de distance entre les vecteurs d'attributs. C'est-à-dire elle est utilisée pour effectuer une classification en aveugle et, ainsi pour réaliser une segmentation sans connaissances a priori sur l'image.

Les algorithmes les plus fréquemment cités dans la littérature pour cette catégorie sont les K-moyennes (K-means), C-moyennes floues (fuzzy C-mean). Cette dernière se divise en deux familles selon deux approches :

- Approches hiérarchique
- Approches non hiérarchique

A) Approche hiérarchique

La classification hiérarchique fournit une hiérarchie de partitions. Ce type de classification regroupe les méthodes ascendantes tel que son principe est de regrouper les objets deux par deux, et descendantes qui consistent à diviser l'ensemble des objets récursivement jusqu'à obtenir le nombre de groupe escompté.

B) Approche non hiérarchique (partitionnelle)

Dans la plupart de ces méthodes, il n'y a pas de hiérarchie. Elles se basent sur le choix a priori du nombre de classes.

Cette méthode consiste à regrouper n individus en k classes de telle sorte que les individus d'une même classe soient le plus semblables possible et que les classes soient bien séparées [6].

Nous distinguons deux types de classification partitionnelle :

- classification nette
- classification floue




Figure I.8: (a)- Classification nette ; (b)- Classification floue.

❖ Classification nette par K-Means

L'algorithme k-Means mis au point par McQueen en 1967 [7], un des algorithmes d'apprentissage non supervisé, également appelé algorithme des centres mobiles [8], c'est l'algorithme de clustering le plus connu et le plus utilisé du fait de sa simplicité de mise en œuvre.

Il partitionne les données d'une image en K clusters. L'algorithme renvoie une partition des données, dans laquelle les objets à l'intérieur de chaque cluster sont aussi proches que possible les uns des autres et aussi loin que possible des objets des autres clusters (figure I.9). Le résultat est un ensemble de clusters compacts et séparés.

Le principe des K-Means est de minimiser la fonction objective [9]:

$$J(x, v) = \sum_{i=1}^N \sum_{k=1}^c \|x_i - v_k\|^2 \quad (1.2)$$

- c est le nombre de classe.
- N est le nombre de données.
- v_k est le centre de classe k .
- $\| \cdot \|$ est la norme Euclidienne qui mesure la similarité entre un pixel et un autre.



Figure I.9: Principe de fonctionnement général de K-Means.

- **Fonctionnement générale de K-Means**




Figure I.10 : Démonstration des quatre étapes de K-Means avec (K=3).

Les principales étapes de l'algorithme K-Means sont [26] :

- 1- Choix aléatoire de la position initiale des K clusters.
- 2- (Ré-) Affecter les objets à un cluster suivant un critère de minimisation des distances (généralement selon une mesure de distance euclidienne).
- 3- Une fois tous les objets placés, recalculer les K centroïdes.
- 4- Répéter les étapes 2 et 3 jusqu'à ce que plus qu'aucune réaffectation ne soit faite.

I.2.3.2 Algorithme des K-means [8]

Paramètres : le nombre K de groupes

Entrée : un échantillon de m objets x_1, \dots, x_m

- 1- choisir K centres initiaux c_1, \dots, c_k
- 2- pour chacun des m objets, l'affecter au groupe i dont le centre c_i est le plus proche
- 3- si aucun éléments ne change de groupe alors arrêter et sortir les groupes
- 4- calculer les nouveaux centres : pour tout i , c_i est la moyenne des éléments du groupe i
- 5- aller en 2



Figure I.11 : Exemple de classification par K-Means.

- **Contraintes**

L'avantage de cet algorithme est avant tout sa grande simplicité et sa rapidité
Mais il à aussi plusieurs points faibles [3] :

- Sensibilité à l'initialisation du fait que les centres initiaux des différentes classes sont choisis aléatoirement.
- K-Means est fortement sensible au bruit.
- Convergence vers un minimum local.

La meilleure solution pour répondre à ces contraintes est l'intégration de la notion de degrés d'appartenance inspirée de la théorie des sous-ensembles flous.

- ❖ **Classification floue**

Le principe de la classification floue est d'affecter un élément à classer non pas à une classe comme dans les approches classiques (K-Means), mais à toutes les classes avec un certain degré. Ce principe découle de ce qu'on appelle la logique floue, qui est venue compléter la logique classique. Nous verrons plus particulièrement et en détails les méthodes de cette classification dans le prochain chapitre.

I.3 Conclusion

Dans ce chapitre, nous avons présenté quelques notions de bases concernant le traitement d'images, nous avons parlé sur l'image numérique et de quoi elle est constituée ainsi que les différentes étapes constituant un système d'analyse d'image. Et enfin nous avons introduit les différentes méthodes de segmentation à savoir :

- La Segmentation à base de contour,
- La Segmentation à base de région,
- La Segmentation par classification.

Notre approche pour la segmentation d'image s'inscrit dans la catégorie des méthodes de segmentation par classification floue qui sera le sujet du prochain chapitre.

Ce deuxième chapitre est reparti en deux parties.

- Dans la première partie, nous allons voir l'algorithme de base de segmentation par classification de pixels qui repose sur les concepts de la logique floue où les pixels de l'image peuvent être regroupés en sous-ensembles flous. Le point clé de la segmentation d'images par classification de pixels est la construction des classes de pixels en présence. Les méthodes de construction des classes telles que les C-moyennes floues (Fuzzy C-Means) et quelques de ses variantes qui intègrent la contrainte spatiale des pixels de l'image seront présentés dans ce qui suit.
 - Dans la deuxième partie, nous présenterons les résultats obtenus en appliquant ces algorithmes sur des images IRM.
-

II.1 Algorithm des Fuzzy C-means standard (FCM)

Fuzzy C-Means (FCM) est un algorithme de classification non-supervisée floue. Issu de l'algorithme des K-means. Il introduit la notion d'ensemble flou dans la définition des classes: chaque point dans l'ensemble des données appartient à chaque cluster avec un certain degré, et tous les clusters sont caractérisés par leur centre de gravité. Comme les autres algorithmes de classification non supervisée, il utilise un critère de minimisation des distances intra-classe et de maximisation des distances inter-classe, mais en donnant un certain degré d'appartenance à chaque classe pour chaque pixel. Cet algorithme nécessite la connaissance préalable du nombre de clusters et génère les classes par un processus itératif en minimisant une fonction objectif [6] :

$$J_m(U, V) = \sum_{i=1}^c \sum_{k=1}^n \mu_{ik}^m d^2(x_k, v_i) \quad (2.1)$$

Où :

- $d^2(x_k, v_i)$ est la norme Euclidienne.
- V_i représente les centroides de la classe i .
- Le paramètre $m > 1$ indice du degré de flou (généralement $m=2$) [12].

II.1.1 Notations

Soit E un ensemble de vecteurs d'attributs, $\{V_1, V_2, \dots, V_c\}$ les centres des différentes classes où c dénote le nombre de classes. Le degré d'appartenance d'un élément x_k à un groupe V_i est noté $\mu_i(x_k)$. Dans cette approche, un vecteur d'attribut donné peut appartenir à plusieurs groupes.

U est la matrice des degrés d'appartenance (appelée également matrice de C-partition floue) de dimension $C \times N$ où C est le nombre de classes et n le nombre d'éléments à classer [10].

$$\forall i, j \mu(x_k) \in \{0,1\} \quad U = [\mu_{ik}(x_k)]$$

$$U = \begin{bmatrix} \mu_{11} & \cdots & \mu_{1n} \\ \vdots & \ddots & \vdots \\ \mu_{c1} & \cdots & \mu_{cn} \end{bmatrix}$$

Trois contraintes sont définies pour la matrice des degrés d'appartenance U :

$$0 \leq \mu_{ik} \leq 1 \quad 1 \leq i \leq c \quad 1 \leq k \leq n \quad (2.2)$$

$$\sum_{i=1}^c \mu_{ik} = 1; \forall k \in [1, n] \quad (2.3)$$

$$0 \leq \sum_{i=1}^c \mu_{ik} \leq 1, \forall i \in [1, c] \quad (2.4)$$

Le FCM est basé sur la mise à jour de la fonction d'appartenance pondent l'itération de l'algorithme :

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}} \right)^{\frac{2}{m-1}}} \quad (2.5)$$

Où μ_{ik} est la fonction de mise à jour des degrés d'appartenance (avec $d_{ik} = \|x_i - c_k\|^2$)

La fonction de mise à jour des centres est :

$$V_i = \frac{\sum_{k=1}^n \mu_{ik}^m x_k}{\sum_{k=1}^n \mu_{ik}^m} \quad (2.6)$$

II.1.2 Algorithme d'exécution du FCM [10]

Etape 1 : fixer les paramètres

C : nombre de classe

ε : seuil représentant l'erreur de convergence (par exemple $\varepsilon = 0.001$),

m: degré de flou, généralement $m = 2$.

Etape 2 : Initialiser la matrice de degrés d'appartenances U par des valeurs aléatoires dans l'intervalle [0 1].

Etape 3 : calculer le prototype v par la relation (2.6).

Calculer $J_m(u, v)$ par la relation (2.1).

Etape 4 : mettre à jour la matrice de degrés d'appartenance par la relation (2.5).

Calculer $J_m(u, v)$ par la relation (2.1).

Etape 5 : répéter les étapes 3 à 4 jusqu'à satisfaction du critère d'arrêt qui s'écrit

$$|J_m^{t+1} - J_m^t| < \varepsilon \text{ (seuil)}$$

II.1.3 La différence entre fuzzy C-Means et k-Means

Nous pouvons résumer la différence entre fuzzy C-means et k-means dans la fonction d'appartenance d'un nuage de points dans deux clusters dans l'exemple suivant :

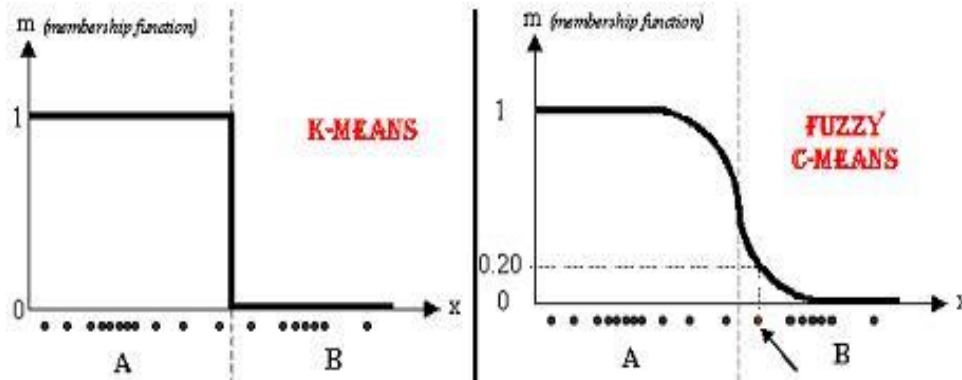


Figure II.1 : Fonction d'appartenance d'un nuage de points avec les deux algorithmes K-means et FCM.

Dans le k-Means, un objet ne peut pas appartenir dans deux clusters simultanément, ce qui explique la discrimination binaire entre les clusters mais en en FCM, il est possible selon différents pourcentages c'est-à-dire que les données sont liées à chaque groupe par le biais d'une fonction d'appartenance, ce qui représente le comportement flou de cet algorithme [13].

II.1.4 Avantages et inconvénients de l'algorithme (FCM)

- Le principal avantage de l'algorithme provient de l'introduction des degrés d'appartenance μ_{ik} grace à eux le processus d'optimisation itératif est rendu beaucoup plus robuste notamment en permettant de prendre en compte les recouvrements entre les classes. Il permet ainsi d'obtenir des partitions plus pertinentes et plus proches de la réalité. En outre ces degrés permettent de prendre des décisions nuancées pour l'assignation d'une forme a une classe ce qui s'avère très intéressant pour toute forme de classification [12].
- Parmi les autres avantages de l'algorithme, sa complexité réduite, son implémentation facile, notamment pour des données importantes qu'il peut traiter [4].

Malgré tout l'algorithme possède aussi quelques inconvénients [13] :

- L'utilisation de la distance Euclidienne, qui suppose que toutes les classes ont des formes hyper-sphériques à diamètre égal, or, cette hypothèse n'est pas vraie, surtout en segmentation d'image. Elle induit en erreur lors de la classification des pixels situés au niveau des frontières entre les régions.
- La sensibilité aux solutions initiales. En effet, l'algorithme FCM ne fournit aucune garantie de convergence vers un optimum global. Différentes initialisations peuvent aboutir à différentes partitions. Dans les FCM la contrainte impose aux degrés d'appartenance des individus fait que les classes sont établies les unes par rapport aux autres. La conséquence directe est la forme particulière des fonctions d'appartenance ; qu'elles soient définies les unes par rapport aux autres et traduisent la notion de "partage" des individus entre les classes. Une autre conséquence de cette notion de partage est que l'algorithme reste assez sensible aux bruits. Afin de remédier au problème du voisinage et la prise en compte de l'information spatiale, l'algorithme FCM-S1 et FCM-S2 correspondent à une telle évolution [13].
- Un inconvénient du modèle standard de FCM dans la segmentation d'image est de ne pas tenir compte de l'information spatiale qui est une relation entre le pixel et ses voisinages. Pourtant, cette information rend l'algorithme très sensible au bruit et à d'autres objets façonnés dans l'image. En fait, cette relation est une des caractéristiques importantes d'une image car les voisinages possèdent souvent les valeurs semblables, et la probabilité qu'ils appartiennent à la même partition est très élevée. Par ailleurs, si nous considérons une image bruitée, le FCM n'est pas une méthode adaptée pour surmonter ce problème.

II.2 Les C-moyennes floues avec contraintes spatiales FCM_S

Le modèle de la classification dans la segmentation d'image est en général un problème de très grande dimension pour lequel, la recherche des méthodes efficaces est toujours d'actualité. Récemment, de nombreux chercheurs ont intégré l'information spatiale à l'algorithme original des FCM pour améliorer l'efficacité de la segmentation d'image.

Dans ce qui suit, nous proposons une modèle adaptatif du FCM appelé FCM-Spatial qui incorpore l'information spatiale à la fonction objective :

$$J_{FCM_S} = \sum_{i=1}^N \sum_{j=1}^c \mu_{ij}^m \left(\sum_{r \in N_i} \|x_r - v_j\|^2 \right) + \frac{\alpha}{N_R} \sum_{i=1}^N \sum_{j=1}^c \mu_{ij}^m \left(\sum_{r \in N_i} \|x_r - v_j\|^2 \right) \quad (2.7)$$

Où :

- α est un paramètre pour contrôler les informations spatiales des voisins avec $0 < \alpha \leq 1$,
- N_i est le paramètre du pixel voisin i ,
- N_R est la cardinalité de N_i .

L'algorithme FCM-S est coûteux en termes de calcul car le terme de voisinage local doit être calculé dans chaque étape d'itération. Pour ce faire, Chen et Zhang remplace le terme $(1 / N_R) \sum_{r \in N_i} \|x_r - v_j\|^2$ avec $\|\bar{x}_i - v_j\|^2$, où \bar{x}_i est l'échelle de gris d'une image filtrée qui pourrait être calculée une fois à l'avance.

L'amélioration pourrait prendre deux formes, à savoir FCM-S1 en utilisant le filtre moyen et FCM-S2 en adoptant le filtre médian [14].

II.2.1 L'algorithme FCM-S1

Pour cette variante du FCM Chen and Zhang [15], ont proposé de remplacer la moyenne des distances des pixels voisins au centre de classe par la distance entre la moyenne des pixels voisins au centre de classe .cela revient a utiliser l'image moyenne déterminée au préalable.

Le nouveau critère est le suivant :

$$J_{FCM-S1} = \sum_{i=1}^N \sum_{j=1}^c \mu_{ij}^m \|x_i - v_j\|^2 + \alpha \sum_{i=1}^N \sum_{j=1}^c \mu_{ij}^m \left\| \bar{x}_i - v_j \right\|^2 \quad (2.8)$$

Où :

- α coefficient de podération.
- \bar{x}_i est la moyenne des voisins dans la fenetre positionnée autour de x_i .

La fonction des degres d'appartenance est

$$\mu_{ik} = \frac{\left(\|x_k - v_i\|^2 + \alpha \|\bar{x}_k - v_i\|^2 \right)^{-\left(\frac{1}{m-1} \right)}}{\sum_{i=1}^c \left(\left(\|x_k - v_i\|^2 + \alpha \|\bar{x}_k - v_i\|^2 \right)^{-\left(\frac{1}{m-1} \right)} \right)} \quad (2.9)$$

La fonction de la mise a jour des centres est :

$$V_i = \frac{\sum_{k=1}^n \mu_{ik}^m (x_k + \alpha \bar{x}_k)}{(1+\alpha) \sum_{k=1}^n \mu_{ik}^m} \quad (2.10)$$

II.2.2 L'algorithme FCM-S2

Pour cette version FCM-S2 le principe été : pour un pixel considéré , calculer la mediane des pixels voisins formant une fenetre n×n (généralement 3×3) de ce dernier. Le pixel actuel n'est affecté à une classe donnée que si la médiane des intensités des voisins est tres proche delintensité du centre de cette classe [4].

La modification aporté a la fonction objective (10) est de remplacer la moyenne des voisins \bar{x}_i par la médiane \tilde{x}_i :

$$J_{FCM-S2} = \sum_{i=1}^N \sum_{j=1}^c \mu_{ij}^m \|x_i - v_j\|^2 + \alpha \sum_{i=1}^N \sum_{j=1}^c \mu_{ij}^m \|\tilde{x}_{i-v_j}\|^2 \quad (2.11)$$

II.2.3 L'algorithme d'execution des FCM-S1 et FCM-S2 [16]

- **Etape 1** : fixer les paramètres C : nombre de classes, ε : seuil représentant l'erreur de convergence (par exemple $\varepsilon=0.001$), m : degré de flou.
- **Etape 2** : Initialiser la matrice de degrés d'appartenances U par des valeurs aléatoires dans l'intervalle [0 1].
- **Etape 3** : calculer le prototype v_i par la relation (2.10). Calculer $J(u, v)$ par la relation (2.8). En utilisant la médiane (\tilde{x}_i) pour FCM_S2 ou la moyenne (\bar{x}_i) pour le FCM_S1.
- **Etape 4** : mettre à jour la matrice degrés d'appartenance par la relation (2.9).

Calculer $J(u, v)$ par la relation (2.8).

- **Etape 5** : répéter les étapes 3 à 4 jusqu'à satisfaction du critère d'arrêt qui s'écrit :

$$|J_m^{t+1} - J_m^t| < \varepsilon$$

II.2.4 Avantages et inconvénients du FCM-S

L'algorithme FCM-S (FCM-S1 et FCM-S2) est très robuste au bruit (sachant que le FCM-S2 est plus performant pour un certain pourcentage du bruit présent dans une image), donc la classification sera bonne.

Son inconvénient majeur est de trouver la valeur optimale du paramètre α . la variation de ce paramètre affecte énormément la qualité de la segmentation.

II.3 FCM régularisé adaptatif avec fonction noyau (ARKFCM) [17]

Cette version de l'algorithme des FCM, utilise l'hétérogénéité des niveaux de gris dans le voisinage des pixels de l'image à segmenter et exploite cette mesure pour l'information contextuelle locale et remplace la distance euclidienne avec des fonctions à base de noyau gaussien.

Les principaux avantages de cet algorithme (ARKFCM) sont l'adaptabilité au contexte local, la robustesse renforcée pour préserver les détails de l'image, l'indépendance des paramètres de classification ainsi que les coûts de calcul réduits.

La modification apporté a la fonction objectif :

$$J_{ARKFCM} = 2 \left[\sum_{i=1}^N \sum_{j=1}^c \mu_{ij}^m (1 - K(x_i, v_j)) + \sum_{i=1}^N \sum_{j=1}^c \varphi_i \mu_{ij}^m (1 - K(\bar{x}_i, v_j)) \right] \quad (2.12)$$

Avec :

- φ_i : Paramètre de régularisation adaptatif associé à chaque pixel pour contrôler le contexte informatif calculé comme suit : $\varphi_i = \begin{cases} 2 + \omega_i & \text{si } \bar{x}_i < x_i \\ 2 - \omega_i & \text{si } \bar{x}_i > x_i \\ 0 & \text{si } \bar{x}_i = x_i \end{cases}$ et $\omega_i = \frac{\alpha_i}{\sum_{k \in N_i} \alpha_i}$

Où :

- $\alpha_i = e^{(\sum_{k \in N_i, i \neq k} LVC_k)}$

Pour être adaptatif au niveau du bruit présent dans un pixel en cours de traitement, le coefficient de variation locale (LVC) est calculé pour estimer l'écart des niveaux de gris à travers une fenêtre glissante (3x3) :

$$LVC_i = \frac{\sum_{k \in N_i} (x_i - \bar{x}_i)^2}{N_R * (\bar{x}_i)^2} \quad (2.13)$$

N_R : Cardinalité de N_i

En présence de bruit pour avoir une forte hétérogénéité entre le pixel central et ses voisins, LVC va augmenter.

- K est la fonction noyau qui remplace la distance euclidienne.

Donc la distance euclidienne $\|x_i - v_j\|^2$ est remplacée par une fonction $\|\phi(x_i) - \phi(x_j)\|^2$ qui est définie par :

$$\|\phi_i - \phi_j\|^2 = K(x_i, x_i) + K(x_i, v_j) - 2K(x_i, v_j) \quad (2.14)$$

Le noyau utilisé est Gaussien :

$$K(x_i, v_j) = e^{\left(-\frac{\|x_i - v_j\|^2}{2\sigma^2}\right)} \quad (2.15)$$

Où : σ est la largeur du noyau et son choix reste un problème qui doit être sélectionné avec soin.

Finalement, l'équation (2.14) devient :

$$\|\phi(x_i) - \phi(x_j)\|^2 = 2(1 - K(x_i, v_j)) \quad (2.16)$$

Les nouveaux centres ainsi que la nouvelle matrice d'appartenance sont mis à jour comme suit :

$$\mu_{ij} = \frac{((1-K(x_i, v_j)) + \varphi_i(1-K(\bar{x}_i, v_j)))^{-\left(\frac{1}{m-1}\right)}}{\sum_{k=1}^c \left((1-K(x_i, v_k)) + \varphi_i(1-K(\bar{x}_i, v_k)) \right)^{-\left(\frac{1}{m-1}\right)}} \quad (2.17)$$

La fonction de la mise à jour des centres est :

$$v_j = \frac{\sum_{i=1}^N \mu_{ij}^m ((1-K(x_i, v_j))x_i + \varphi_i(1-K(\bar{x}_i, v_j))\bar{x}_i)}{\sum_{i=1}^N \mu_{ik}^m ((1-K(x_i, v_j)) + \varphi_i(1-K(\bar{x}_i, v_j)))} \quad (2.18)$$

II.3.1 Algorithme d'execution du ARKFCM

- **Etape 1** : fixer les paramètres C : nombre de classes, ε : seuil représentant l'erreur de convergence (par exemple $\varepsilon=0.001$), m : degré de flou.
- **Etape 2** : Initialiser la matrice de degrés d'appartenances U par des valeurs aléatoires dans l'intervalle $[0, 1]$.
- **Etape 3** : Calculer le paramètre de régularisation adaptatif φ_i
- **Etape 4** : mettre à jour la matrice degrés d'appartenance par la relation (2.16) et les nouveaux centres par (2.17).
Calculer $J(u, v)$ par la relation (2.8).
- **Etape 5** : répéter les étapes 4 à 5 jusqu'à satisfaction du critère d'arrêt qui s'écrit :

$$|J_m^{t+1} - J_m^t| < \varepsilon$$

Dans ce qui suit, nous nous intéressons aux images médicales IRM du cerveau en vue d'une segmentation des différents tissus qui le constitue. Pour cela nous allons d'abord faire quelques rappels sur l'anatomie du cerveau pour mieux comprendre les images à étudier.

II.4 Imagerie par résonance magnétique (IRM)

L'imagerie par résonance magnétique (IRM) constitue une des avancées les plus significatives en médecine; elle est issue des travaux sur les propriétés magnétiques des noyaux des atomes menés par F. Bloch et E. Purcell en 1946 [18].

L'imagerie par Résonance Magnétique nucléaire (IRM) est une technique d'imagerie médicale d'apparition récente, non invasive et sans effets secondaires fournissant des images tridimensionnelles d'une partie du corps, notamment du cerveau et en coupe (bidimensionnelle) de grande précision anatomique. Elle est basée sur le phénomène physique de résonance magnétique nucléaire [28]. Il s'agit simplement d'observer la résonance magnétique nucléaire (RMN) des protons de l'eau contenus dans l'organisme [18].

Le principe consiste à mesurer l'aimantation des tissus biologiques et à reconstruire une image à partir de ces aimantations. Cette dernière est induite par l'hydrogène, qui s'y trouve en abondance dans le corps humain.

II.5 Anatomie cérébrale

II.5.1 Le cerveau

Le cerveau est l'organe principal du système nerveux central. Il est formé essentiellement de deux hémisphères, le cerveau est une structure très complexe qui peut porter jusqu'à plusieurs milliards de neurones connectés les uns aux autres. Les neurones sont les cellules cérébrales qui communiquent entre elles par le biais de longues appelées axones.

Le cerveau est composé de substances (ou matières) : la matière blanche et la matière grise et baigne dans un liquide appelé liquide céphalo-rachidien (Figure II.2).




Figure II.2 : Cerveau humain composé des substances.

II.5.1.1 La matière blanche (MB)

La matière blanche (figure II.2) se situe dans la partie interne du cerveau. Elle correspond à la gaine de myéline qui recouvre les axones des neurones qui établissent les connexions entre les corps cellulaires du cortex et d'autres parties du cerveau.

II.5.1.2 La matière grise (MG)

Ce tissu (figure II.2) est réparti en deux structures, les noyaux et le cortex. Le cortex est une couche superficielle épaisse recouvrant le cerveau et est variable pour chaque individu. D'un autre côté les noyaux gris sont des regroupements de substance grise, situés à l'intérieur du cerveau. Ils sont constitués du noyau caudé, du putamen, du globus pallidus, du corps de Luys et la substance noire.

II.5.1.3 Le liquide céphalo-rachidien (LCR)

Le liquide céphalo-rachidien est un liquide biologique transparent constitué de 99% d'eau, entoure le cerveau et remplit les ventricules, il permet de protéger le cerveau des chocs en jouant le rôle d'amortisseur, et remplit des fonctions importantes dans les échanges entre le sang et les tissus nerveux.

II.5.2 Lésions cérébrales

Une lésion cérébrale est une lésion qui touche le cerveau. En général, il s'agit d'une destruction plus ou moins étendue du tissu nerveux entraînant un déficit dans la perception, la cognition, la sensibilité ou la motricité en fonction du rôle que jouait la région atteinte dans l'architecture neurocognitive. Cette lésion peut être de nature diverse : ischémique, hémorragique, compressive par un processus expansif de type tumoral ou un hématome.

II.5.2.1 Tumeur cérébrale

Le cerveau peut être le siège de près d'une dizaine de types de tumeurs qui sont classées selon les cellules qui les composent. Une tumeur est toute masse qui résulte d'une multiplication (division) accrue de cellules anormales. Elle peut être également appelée un néoplasme ou une excroissance (masse) [27].




Figure II.3 : Image IRM normale et en présence d'une tumeur.

- Les tumeurs cérébrales dites «primaires» sont celles qui se développent directement à partir des cellules du cerveau et de son enveloppe. Elles peuvent être bénignes ou malignes.
- Les tumeurs cérébrales secondaires (ou métastatiques) sont constituées de cellules provenant d'un autre organe, le plus souvent des poumons, des seins, des reins ou de la peau (mélanome). Les cellules tumorales de ces organes peuvent migrer vers le cerveau en empruntant le plus souvent la voie sanguine.

Il existe deux tumeurs cérébrales :

a) Les tumeurs cérébrales bénignes

Les tumeurs cérébrales bénignes sont constituées de cellules qui croissent lentement et qui, à l'analyse microscopique n'ont pas de caractère d'activité importante. Une tumeur cérébrale bénigne peut être soit simplement surveillée radiologiquement soit être extirpée chirurgicalement complètement ou de façon partielle. Si une tumeur bénigne n'est pas complètement enlevée, elle peut récidiver [27].

b) Les tumeurs cérébrales malignes

Les tumeurs cérébrales malignes contiennent des cellules qui se multiplient relativement vite, ces tumeurs croissent donc rapidement. Elles consomment beaucoup d'énergie, leurs

contours sont mal limités et aussi elles peuvent envahir endommager des structures cérébrales importantes [19].

II.6 Artefacts des images IRM

Les erreurs (artefacts) d'acquisition en IRM sont de natures différentes de celles observées dans d'autres domaines du traitement d'images. On distingue essentiellement quatre effets : le mouvement, les variations de champ et surtout le bruit [20].

II.6.1 Le mouvement

Le mouvement peut provenir de plusieurs sources. Il peut être lié au métabolisme comme la circulation sanguine ou la respiration. Il peut également être lié au mouvement du patient pendant l'acquisition de l'image IRM.

II.6.2 Variations du champ magnétique

Les variations de champ ont pour conséquence une variation des intensités d'un même tissu dans une direction quelconque de l'image. Ce phénomène est dû au fait que le champ magnétique n'est pas parfaitement homogène spatialement et temporellement pendant l'acquisition de l'image IRM.

II.6.3 Le bruit

Le bruit a des origines multiples, liées en partie au bruit de l'appareillage. Dans les images par résonance magnétique, l'objectif est d'augmenter le contraste entre les tissus tout en conservant une bonne résolution et un rapport signal bruit élevé, ces caractéristiques sont cependant contradictoires et il est nécessaire de trouver un bon compromis entre résolution et bruit.

a) Le bruit impulsionnel (Salt and Pepper)

Le bruit impulsionnel permet de modéliser le cas où certains pixels sont saturés ou morts.

b) Le bruit Gaussien

Obtenu en ajoutant à chaque pixel une valeur aléatoire distribuée identiquement et indépendamment suivant une loi gaussienne (de moyenne $m = 0$ et de variance σ).

II.7 Segmentation d'une image IRM sans bruit

Afin de tester la sensibilité et la robustesse des différents algorithmes vis-à-vis du bruit, nous avons ajouté à l'image médicale de la figure II.4 composée de 4 classes (Matière Blanche **MB**, Matière Grise **MG**, le Liquide Céphalo-rachidien **LCR** et l'arrière plan) un bruit gaussien ainsi un autre bruit de type salt & pepper.




Figure II.4 : Image médicale originale



Image segmentée




Figure II.5: Résultat de la segmentation par les K-Means.




Figure II.6: Résultat de la segmentation par les FCM.

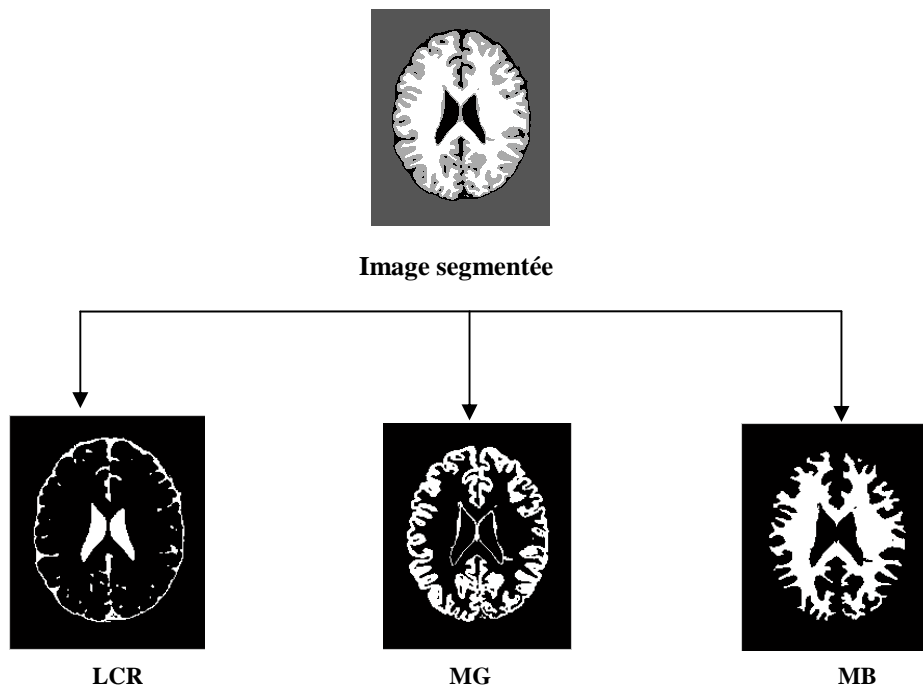


Figure II.7: Résultat de la segmentation par les FCM_S1.




Figure II.8: Résultat de la segmentation par les FCM_S2.




Figure II.9: Résultat de la segmentation par ARKFCM.

Les figures (II.5) à (II.9) représentent les résultats de la segmentation de l'image originale (figure II.2) en utilisant respectivement les algorithmes K-Means, FCM, FCM-S1, FCM-S2, ARKFCM.

D'après les résultats obtenus, nous remarquons bien que les cinq algorithmes ont pu segmenter l'image originale en 4 classes; (LCR, MG, MB ainsi que le fond de l'image qui est ignoré dans notre étude). Nous constatons visuellement que les résultats sont presque similaires pour les cinq algorithmes en fournissant une bonne segmentation.

II.8 Segmentation d'une image IRM en présence d'un bruit

Dans le but de différencier entre les performances des cinq algorithmes, l'image originale est noyée dans du bruit avant de la segmenter. Les résultats de la segmentation sont illustrés ci-dessous :

a) Bruit Salt&Pepper de variance $\sigma = 0.02$

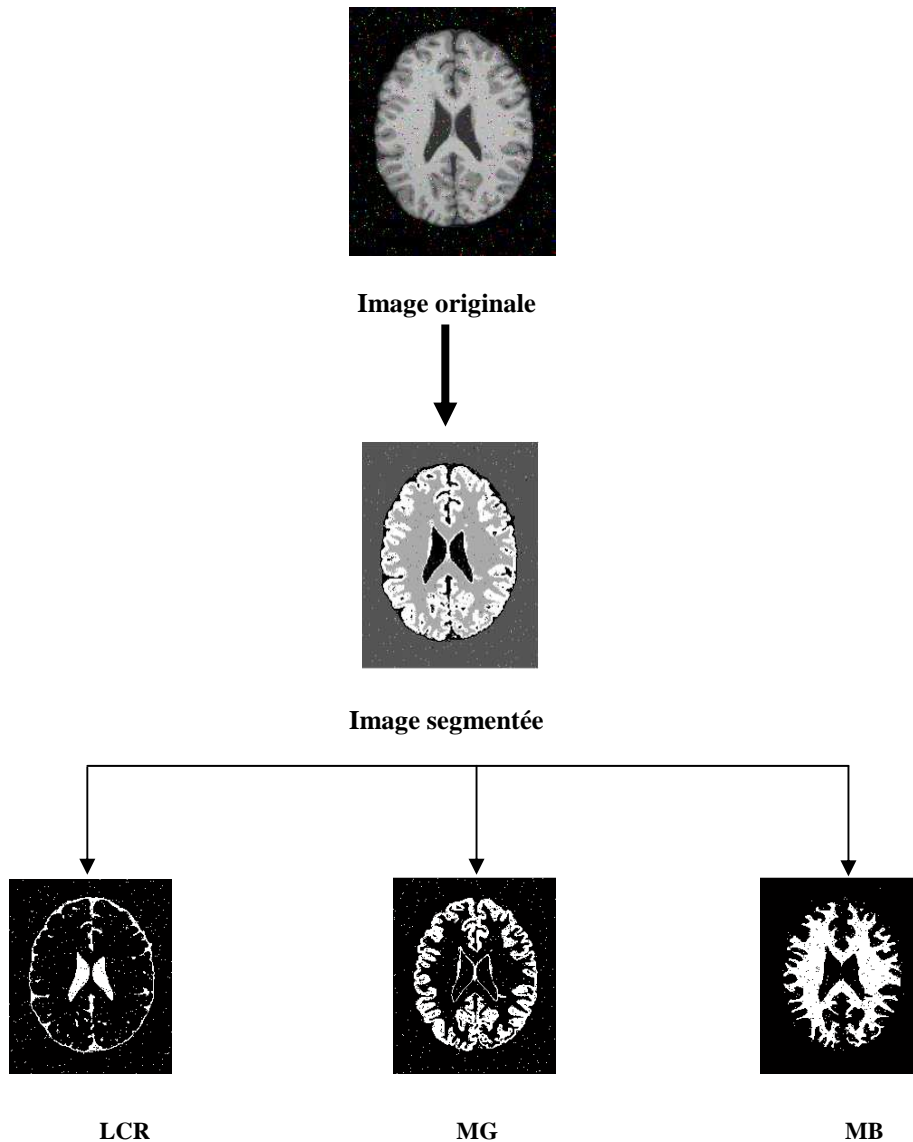


Figure II.10 : Résultat de la segmentation par les K-means d'une image bruitée avec Salt & Pepper.




Figure II.11 : Résultat de la segmentation par les FCM d'une image bruitée avec Salt & Pepper.

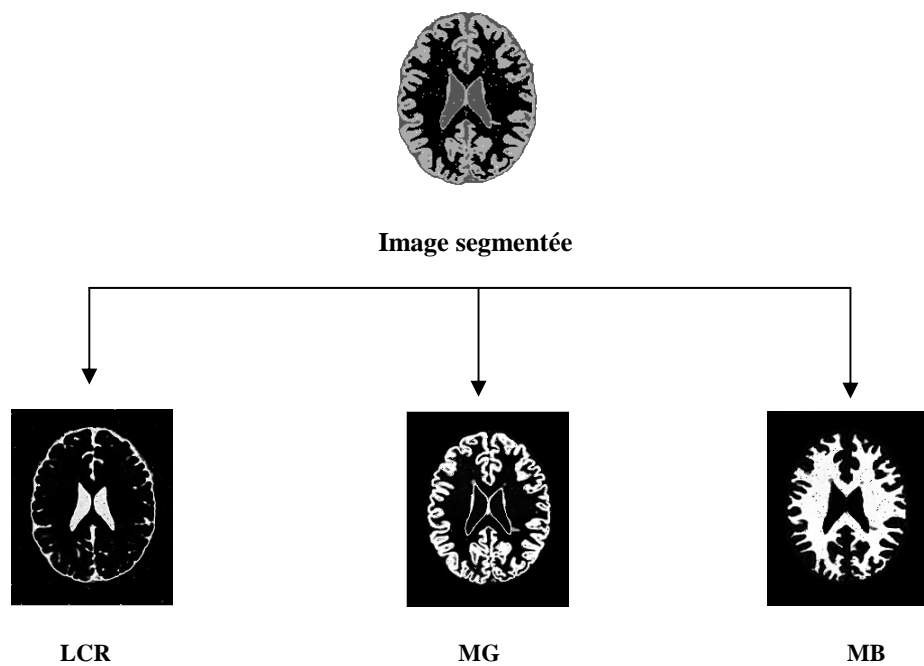


Figure II.12 : Résultat de la segmentation par les FCM-S1 d'une image bruitée avec Salt & Pepper.




Figure II.13 : Résultat de la segmentation par les FCM-S2 d'une image bruitée avec Salt & Pepper.

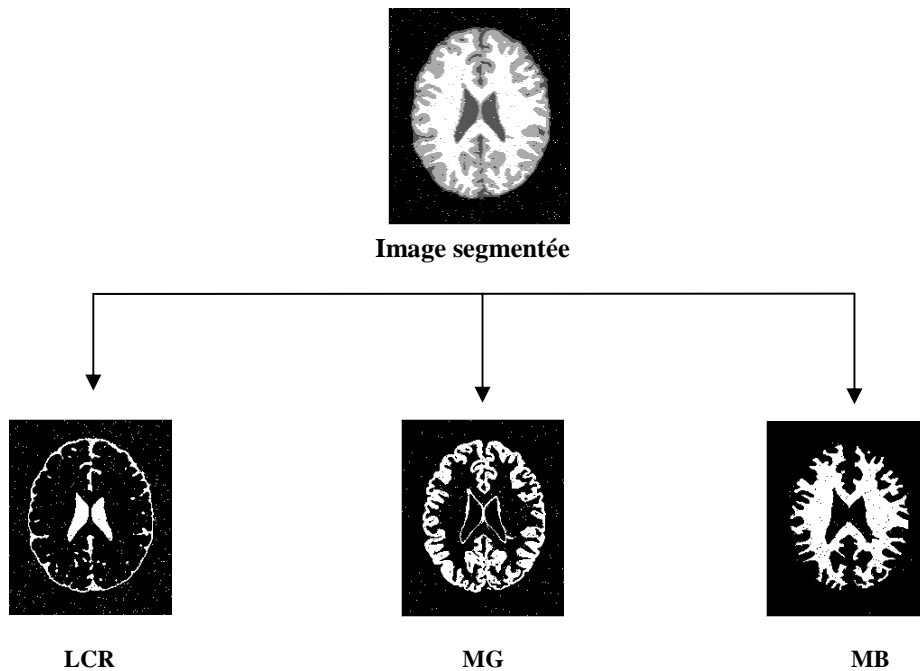


Figure II.14 : Résultat de la segmentation par ARKFCM d'une image bruitée avec Salt & Pepper.

b) Bruit Gaussien de moyenne nulle ($m=0$) et de variance $\sigma =0.01$

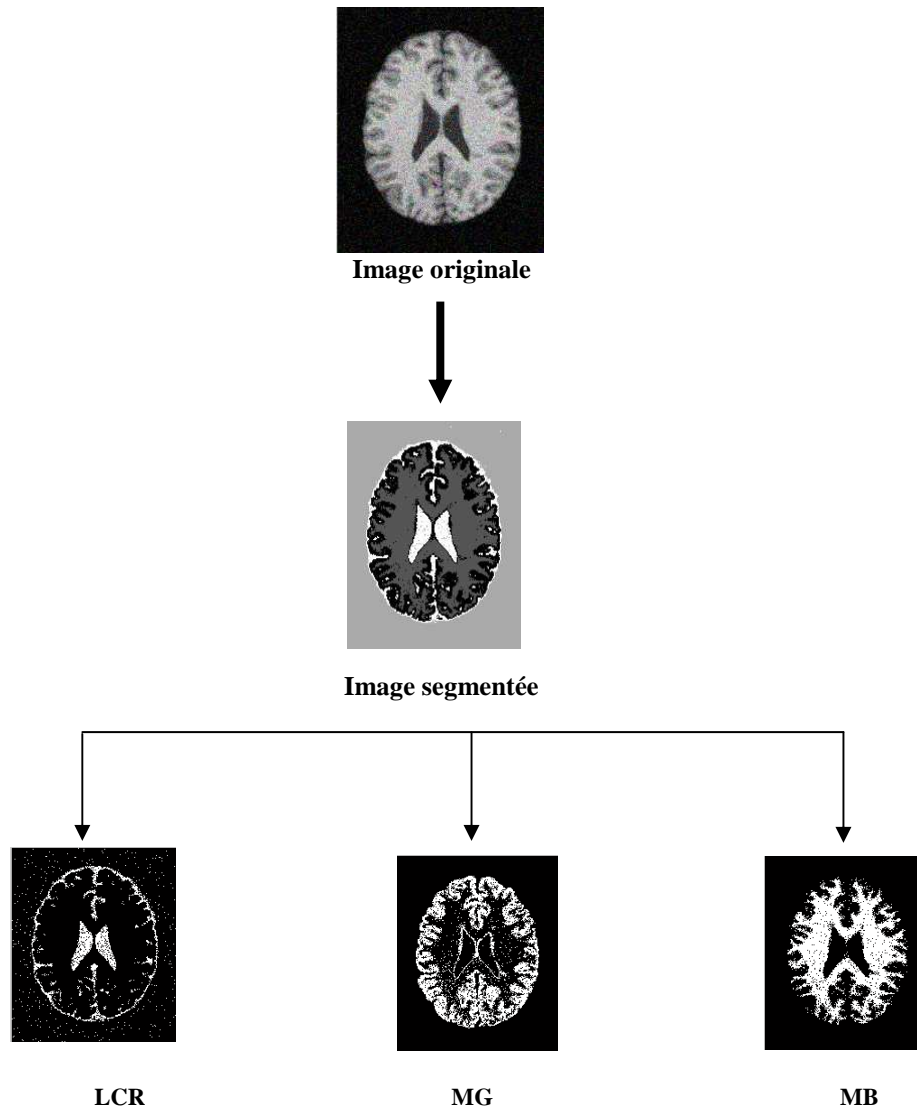


Figure II.15 : Résultat de la segmentation par les K-Means d'une image avec un bruit Gaussien.




Figure II.16 : Résultat de la segmentation par le FCM d'une image avec un bruit Gaussien.




Figure II.17 : Résultat de la segmentation par le FCM-S1 d'une image avec un bruit Gaussien.




Figure II.18 : Résultat de la segmentation par le FCM-S2 d'une image avec un bruit Gaussien.

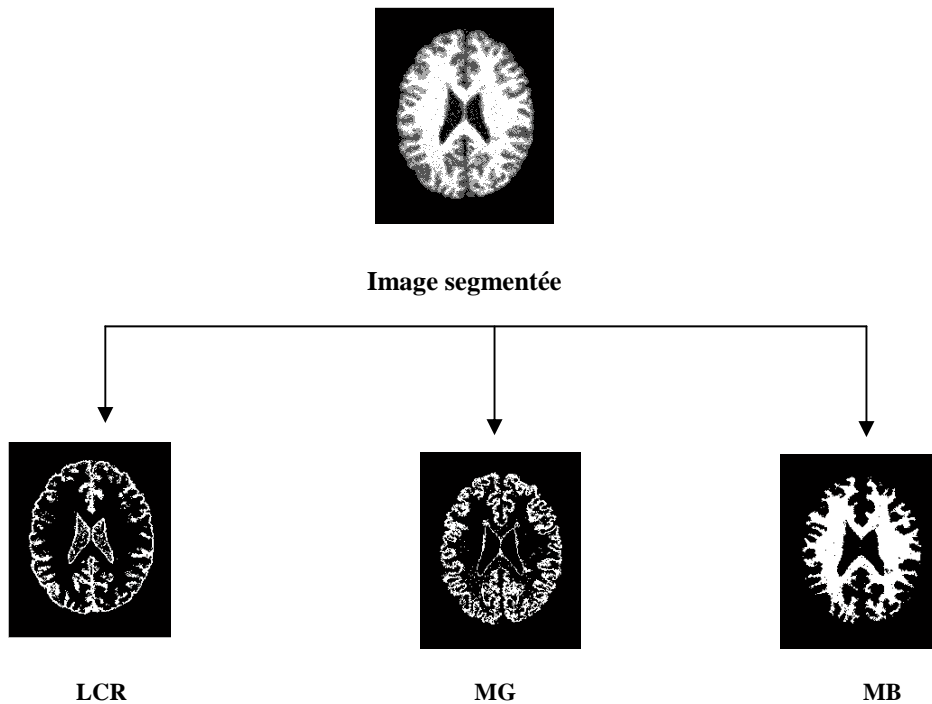


Figure II.19 : Résultat de la segmentation par ARKFCM d'une image avec un bruit Gaussien.

Chapitre II : Segmentation par l'algorithme des Fuzzy C-Means

Les résultats retrouvés dans le cas où l'image originale est bruitée (par un bruit gaussien ou Salt and Pepper) sont différents pour les cinq algorithmes. Les deux variantes du FCM-S (FCM-S1 et FCM-S2) n'ont pas apporté une amélioration pour la segmentation de l'image bruitée.

Afin d'estimer de manière quantitative les résultats de segmentation obtenus, un indice est calculé, permet de comparer deux images notées A pour l'image segmentée et B pour l'image vérité terrain. Le coefficient de Jaccard $J(A;B)$ mesure le recouvrement entre A et B. Les meilleures performances sont obtenues pour des valeurs élevées de cet indice qui est défini par :

$$Jaccard = \frac{A \cap B}{A \cup B} \quad (2.19)$$

Le coefficient de Dice $D(A;B)$ mesure également le recouvrement entre A et B et est défini par :

$$Dice = \frac{2|A \cap B|}{|A| + |B|} \quad (2.20)$$

$D(A;B)$ vaut 1 en cas de correspondance parfaite entre les deux images A et B, et 0 si le recouvrement est nul.

	Image sans bruit			Image avec bruit Salt & Pepper			Image avec bruit Gaussien		
	LCR	MB	MG	LCR	MB	MG	LCR	MB	MG
K-Means	0,875	0,9514	0,8788	0,7499	0,9138	0,8131	0,5769	0,8033	0,6602
FCM	0,8696	0,9501	0,879	0,8536	0,9396	0,8612	0,4013	0,7218	0,5866
FCM-S1	0,861	0,9447	0,8612	0,8442	0,9321	0,8427	0,5742	0,8292	0,6536
FCM-S2	0,8604	0,947	0,871	0,8558	0,9386	0,8508	0,6612	0,747	0,671
ARKFCM	0,8642	0,9596	0,8785	0,8872	0,9371	0,8601	0,773	0,8493	0,738

Tableau II.1 : Résultats obtenus pour les cinq algorithmes K-Means, FCM, FCM-S1, FCM-S2, ARKFCM sans bruit et avec bruit. (Indice de Jaccard).




Figure II.20 : Evaluation des performances des différents algorithmes (Indice de Jaccard).

	Image sans bruit			Image avec bruit Salt & Pepper			Image avec bruit Gaussien		
	LCR	MB	MG	LCR	MB	MG	LCR	MB	MG
K-Means	0,9339	0,9786	0,9381	0,8941	0,9612	0,9055	0,7849	0,9056	0,8054
FCM	0,9398	0,9779	0,9386	0,9299	0,9723	0,9286	0,6793	0,8517	0,7509
FCM-S1	0,9369	0,9754	0,9291	0,9306	0,9695	0,9183	0,7668	0,9202	0,8014
FCM-S2	0,9367	0,9768	0,9339	0,9358	0,9726	0,9284	0,7741	0,9267	0,8106
ARKFCM	0,9403	0,9785	0,9367	0,9451	0,9733	0,9287	0,8938	0,9297	0,8514

Tableau II.2 : Résultats obtenus pour les cinq algorithmes K-Means, FCM, FCM-S1, FCM-S2, ARKFCM sans bruit et avec bruit. (Indice de Dice).

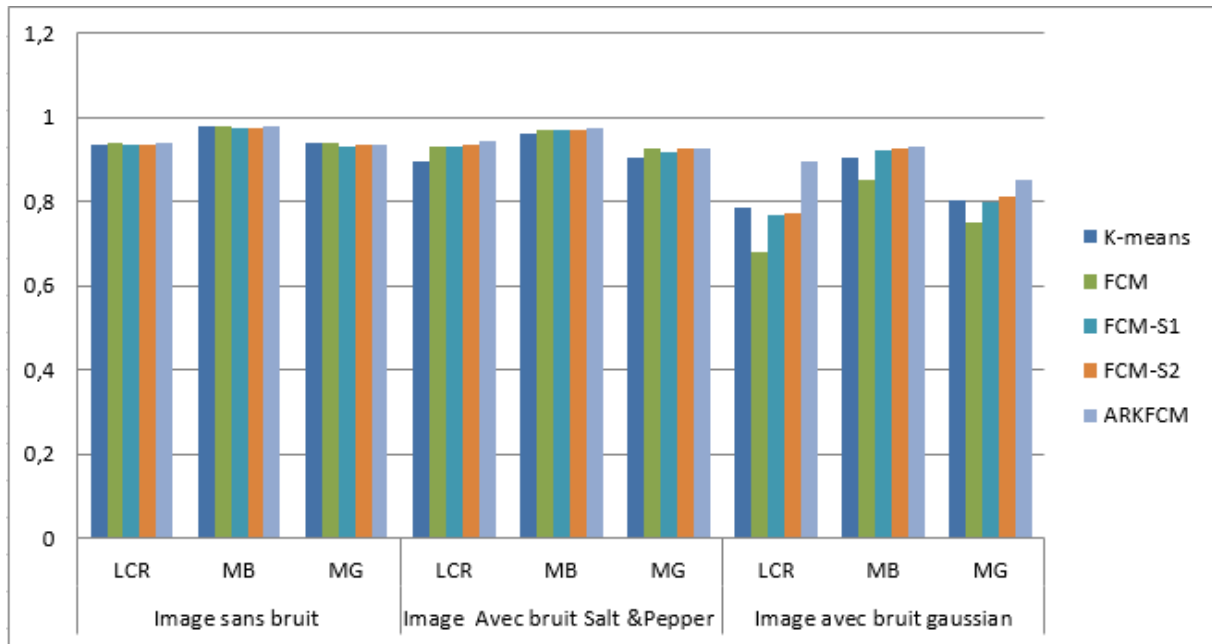


Figure II.21 : Evaluation des performances des différents algorithmes (Indice de Dice).

Les tableaux II.1 et II.2 montrent que l'algorithme ARKFCM donne de meilleurs résultats et surpasse les autres algorithmes, en particulier, en présence du bruit. Les comparaisons quantitatives des algorithmes confirment l'évaluation visuelle. Ces résultats sont également illustrés sur les figures (II.20) et (II.21).

II.9 Conclusion

Dans ce chapitre nous avons étudié quelques variantes du FCM qui incorpore le contexte spatiale dans la fonction objectif ce qui a rendu l'algorithme de classification plus performant par rapport au FCM standard.

Nous avons présenté une récente méthode de segmentation d'image appelé ARKFCM qui est venue pour surmonter un peut les inconvénients du FCM comme sa sensibilité au bruit et la forme des classes qui est sphérique ainsi que la dépendance de ses résultats à l'initialisation des centres de classes.

Les résultats de segmentation obtenus sur des images IRM en absence et en présence du bruit, démontrent clairement la robustesse de l'ARKFCM à ce dernier.

Dans le prochain chapitre, et afin de procéder à l'extraction et à la classification d'une tumeur en cas de présence de cette dernière au niveau du cerveau, nous allons poursuivre notre travail en se basant sur le résultat de la segmentation obtenu par le ARKFCM vu les performances qu'il présente.

Délimiter ou segmenter, les structures cérébrales est une étape fondamentale pour l'analyse d'images IRM. Elle permet de réaliser une séparation des différents tissus cérébraux ainsi que d'éventuelles pathologies cérébrales telle que la présence de tumeurs. Une bonne segmentation permet d'aider le praticien à prendre une décision finale, avant son geste chirurgical.

Afin de détecter la tumeur, nous utilisons l'algorithme ARKFCM décrit dans le chapitre précédent vu ses performances de segmentation. Le processus d'extraction du cerveau nous fournit une première estimation des principaux tissus (MG, MB, LCR, fond d'image et tumeur). Par la suite la sélection de la classe représentant la tumeur nous permet d'extraire un ensemble de caractéristiques afin de les exploiter en vue d'une classification de cette dernière en **tumeur Bénigne** et **tumeur Maligne**.

III.1 Processus de classification de la tumeur

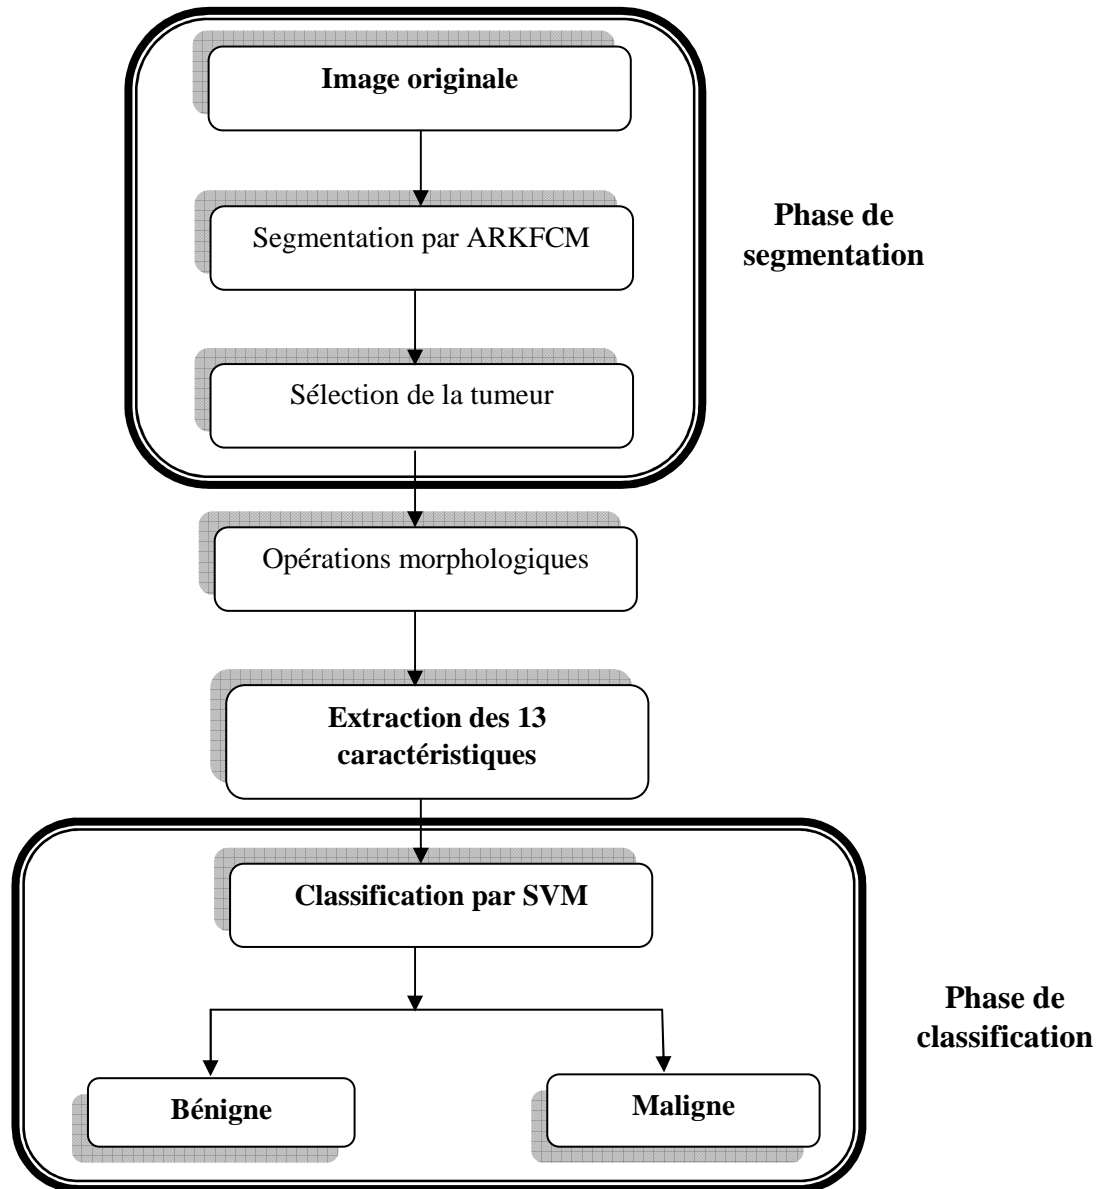


Figure III.1 : Processus de classification.

III.1.1 Base de données utilisées

Dans ce travail, la base de données utilisée se compose d'images IRM cérébrales de dimensions 256X256 pixels, ont été téléchargés à partir du site web de la Harvard Medical School (<http://med.harvard.edu/AANLIB/>).

Les images IRM cérébrales de l'ensemble de données comprennent les maladies suivantes: gliome, méningiome, maladie d'Alzheimer, maladie d'Alzheimer et agnosie visuelle, maladie de Pick, sarcome et maladie de Huntington.

III.1.2 Opérations morphologiques

Les opérations morphologiques sont des outils d'analyse et de filtrage des images, qui peuvent s'appliquer tant aux images binaire qu'à celles à niveaux de gris.

Le principe de base de ces opérations est de comparer l'image à analyser à un ensemble de géométrie connue appelé élément structurant ou noyau. On déplace cet élément structurant de façon à ce que son origine passe par toutes les positions de l'image, afin d'en mettre en évidence certaines caractéristiques. Les opérations de base de la morphologie mathématique sont deux opérations appelées érosion et dilatation. Des combinaisons de ces opérateurs permettent de filtrer les images du point de vue morphologique, c'est-à-dire supprimer (ou mettre en valeur) des formes sur l'image comparables aux éléments structurants utilisés. C'est le cas de l'ouverture (succession d'une dilatation et d'une érosion utilisant le même élément structurant) et de la fermeture (succession d'une érosion et d'une dilatation utilisant le même élément structurant).




Figure III.2: Principe de fonctionnement des opérations morphologiques.

a) Érosion

L'érosion est définis (pour une image binaire en noir et blanc) comme:

$$\epsilon_B(A) = A \ominus B \quad (3.1)$$

Où : A correspond à l'image binaire à traiter et B l'élément structurant avec lequel on parcourt l'image. L'érosion a pour effet d'éliminer les objets ou certaines parties d'objets dont la taille est inférieure à celle de l'élément structurant. Certains objets connectés peuvent également être séparés.

b) Dilatation

La dilatation est définis (pour une image binaire en noir et blanc) comme:

$$\delta_B(A) = A \oplus B \quad (3.2)$$

Où : A correspond à l'image binaire à traiter et B l'élément structurant avec lequel on parcourt l'image.

A l'inverse de l'érosion, la dilatation a pour effet d'augmenter la taille des objets, et de fusionner certains d'entre eux, lorsque la distance qui les sépare est inférieure à la taille de l'élément structurant.




Figure III.3: érosion (gauche) et dilatation (droite) de l'objet binaire en utilisant un élément structurant B circulaire.

III.1.3 Segmentation par ARKFCM

Nous appliquons l'algorithme ARKFCM en première phase afin de segmenter une image IRM ayant une tumeur au niveau du cerveau et nous procédons à l'extraction de l'ensemble des classes contenues dans l'image choisie.




Figure III.4: Image avec tumeur et le résultat de segmentation par ARKFCM.




Figure III.5: Résultat de la segmentation classe par classe.

En sélectionnant la classe représentant la tumeur et en appliquant les opérations morphologiques, nous aurons le résultat suivant (figure III.6).



Figure III.6: Résultat de l'opération morphologique sur la tumeur.

III.1.4 Extraction des caractéristiques

Afin d'identifier les caractéristiques qui représentent au mieux la tumeur nous procédons à l'extraction des caractéristiques uniquement à partir de la classe représentant la tumeur.

Le processus d'extraction du vecteur de caractéristiques de référence est représenté par l'organigramme suivant (figure III.7).

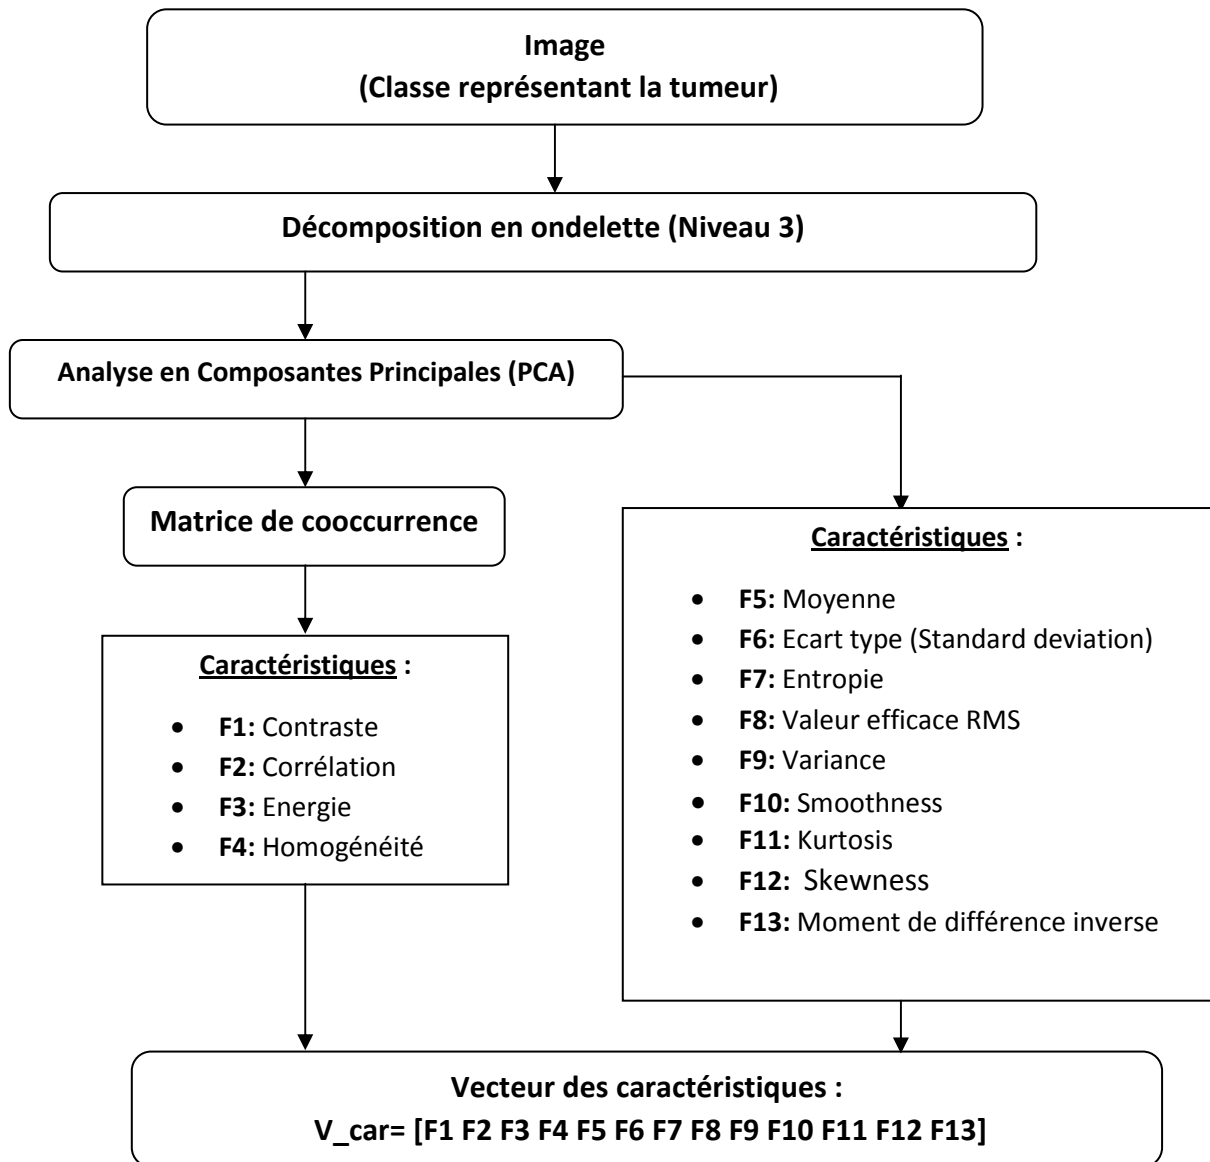


Figure III.7: Processus d'extraction des caractéristiques de la tumeur.

III.1.4.1 Transformée en ondelettes discrète [21]

Cette méthode peut être vue comme une nouvelle avancée dans le domaine de l'analyse du signal (par rapport à la transformée de Fourier), étant donné qu'elle offre la possibilité de produire une information localisée en termes de temps et de fréquence.

La transformée en ondelettes continue d'une fonction quadratiquement intégrable $x(t)$ par rapport à une ondelette $\psi(t)$ s'écrit :

$$w_{\psi}(a, b) = \int_{-\infty}^{+\infty} x(t)\psi_{a,b}(t)dt \quad (3.3)$$

Tel que :

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}}\psi\left(\frac{t-a}{b}\right) \quad (3.4)$$

L'ondelette $\psi_{a,b}(t)$ est calculée à partir de l'ondelette mère $\psi(t)$ par translation et dilatation: a et b sont respectivement les facteurs de dilatation et de translation.

Il existe plusieurs types d'ondelettes la plus importante est l'ondelette de Harr, qui est la plus simple et souvent l'ondelette préférée dans beaucoup d'applications.

La transformée en ondelettes discrète s'obtient en contraignant les paramètres a et b au sein d'une grille discrète ($a=2^b$ & $a>0$) :

$$Ca_{j,k}(n) = DS[\sum_n x(n)g_j(n - 2^j k)] \quad (3.5)$$

$$Cd_{j,k}(n) = DS[\sum_n x(n)h_j(n - 2^j k)]$$

- $Ca_{j,k}, Cd_{j,k}, g(n), h(n)$ décrivent les coefficients d'approximation, les coefficients de détail, le filtre passe-bas, et le filtre passe-haut, respectivement.
- j et k représentent l'échelle de l'ondelette et le facteur de translation, respectivement. DS désigne l'opérateur de sous échantillonnage.

L'équation (3.5) est la fondamentale de la décomposition en ondelettes. Il décompose le signal $x(n)$ en deux signaux, les coefficients d'approximation $Ca(n)$ et les composantes de détail $Cd(n)$. Cette procédure est appelée décomposition à un niveau.

Le processus de décomposition ci-dessus peut être itéré avec des approximations successives décomposées à tour de rôle, de sorte qu'un signal est décomposé en différents niveaux de résolution. L'ensemble du processus est appelé arbre de décomposition en ondelettes, représenté sur la figure III.9. La transformée en ondelettes discrète s'applique à une image, en filtrant de manière successive ses lignes et ses colonnes. À un niveau donné, la décomposition produit une approximation LL du signal original, et trois types de détails (horizontaux LH, verticaux HL, et diagonaux HH). L'utilisation de plusieurs niveaux de décomposition permet d'explorer les caractéristiques de l'image sur plusieurs niveaux de résolution (du plus fin au plus grossier).

Dans notre algorithme, la décomposition de niveau 3 via l'ondelette de "Daubechie" a été utilisée pour extraire des caractéristiques.




Figure III.8: Arbre de décomposition niveau 3




Figure III.9 : Transformée en ondelettes discrète s'applique à une image.

III.1.4.2 Analyse en Composantes Principales (PCA)

L'analyse en composantes principales (PCA) est un outil efficace pour réduire la dimension d'un ensemble de données constitué d'un grand nombre de variables interdépendantes tout en conservant la plupart des variations. Il est réalisé en transformant l'ensemble de données en un nouvel ensemble de variables ordonnées en fonction de leurs variances ou de leur importance.

III.1.4.3 Matrice de cooccurrence

La matrice de cooccurrence a été introduite par Haralick en 1973 [22], elle est largement utilisée dans l'analyse de texture. Elle est très facile à mettre en œuvre et donne de bons résultats sur plusieurs types de texture. Dans la plupart des applications, les images utilisées sont représentées en niveaux de gris et la matrice de cooccurrence est connue sous le nom GLCM (Gray Level Co-occurrence Matrix).




Figure III.10: Transformation d'une image à GLCM. (a) : Image (b) : Son GLCM.

Une matrice de cooccurrence est une matrice de taille $N \times N$, où N est le nombre de niveaux de gris d'une image. Pour un déplacement \mathbf{d} (translation), un élément (i, j) de la matrice est défini par le nombre de pixels de l'image de niveau de gris j situés à \mathbf{d} d'un pixel de niveau de gris i .

Les matrices de cooccurrence contiennent une masse très importante d'informations et sont donc difficilement manipulables, de ce fait, Plusieurs indices ont été proposé par Haralick qui correspondent à des caractères descriptifs des textures peuvent être calculés à partir de ces matrices. Plusieurs caractéristiques de texture peuvent être extraites à partir de la GLCM comment : le contraste, la corrélation, l'énergie et l'homogénéité.

Dans ce qui suit, nous allons présenter les treize (13) caractéristiques (F1 à F13) que nous utiliserons durant le processus de classification de la tumeur :

a) F1: Contraste [23]

$$\sum_{i,j} |i - j|^2 p(i, j) \quad (3.6)$$

Est une propriété intrinsèque d'une image qui quantifie la différence de luminosité entre les parties claires et les parties sombres d'une image.

b) F2: Correlation [24]

$$\sum_{i,j} \frac{(i - \mu_i)(j - \mu_j)p(i, j)}{\sigma_i \sigma_j} \quad (3.7)$$

La corrélation mesure la dépendance linéaire des niveaux de gris de l'image. Elle n'est corrélée ni à l'énergie, ni à l'entropie.

c) F3: Energie [23]

$$\sum_{i,j} p(i, j)^2 \quad (3.8)$$

Mesure l'uniformité de la texture qui est la répétition des paires de pixels.

d) F4: Homogénéité [24]

$$\sum_{i,j} \frac{p(i, j)}{1 + (i - j)^2} \quad (3.9)$$

Renvoie une valeur qui mesure la proximité de la distribution des éléments dans la diagonale GLCM.

e) F5: La moyenne

$$\frac{1}{N} \sum_{i,j} p(i,j) \quad (3.10)$$

N: dimension de l'image.

Les valeurs d'intensité moyennes des pixels sont indiquées par cette caractéristique.

f) F6: Ecart type (Standard deviation) [25]

$$\sqrt{\sum_{i=0}^{l-1} (i - m)^2 p(i,j)} \quad (3.11)$$

m : valeur moyenne de $p(i,j)$.

Il est beaucoup plus informatif, il indique la variabilité des niveaux de gris, c'est-à-dire, le changement du contraste.

g) F7: Entropie [23]

$$-\sum_{i,j} p(i,j) \log p(i,j) \quad (3.12)$$

Ce paramètre mesure le désordre dans l'image. Contrairement à l'énergie, l'entropie atteint de fortes valeurs lorsque la texture est complètement aléatoire (sans structure apparente). Elle est fortement corrélée (par l'inverse) à l'énergie.

h) F8: Valeur efficace (RMS)

$$\sqrt{\frac{1}{N} \sum_{i,j} p(i,j)^2} \quad (3.13)$$

i) F9: Variance [23]

$$\sum_{i,j} (i + j - m)^3 * p(i,j) \quad (3.14)$$

La variance mesure l'hétérogénéité de la texture. Elle augmente lorsque les niveaux de gris différent de leur moyenne. La variance est indépendante du contraste.

j) F10: Smoothness [25]

$$1 - \frac{1}{1 + \sum_{i=0}^{l-1} (i-m)^2 p(i,j)} \quad (3.15)$$

Il mesure la douceur relative de l'intensité dans une région. Ceci est égal à 0 pour une région d'intensité constante et se rapproche de 1 pour les régions avec une variabilité dans les valeurs de ses niveaux d'intensité.

k) F11: Kurtosis

$$\sum_{i=0}^{l-1} (i - m)^4 p(i, j) \quad (3.16)$$

l) F12 : Coefficient d'asymétrie (Skewness) [23]

$$\sum_{i=0}^{l-1} (i - m)^3 p(i, j) \quad (3.17)$$

L'asymétrie est une mesure de l'asymétrie des données autour de la moyenne de l'échantillon. La valeur d'asymétrie peut être positive ou négative ou indéfinie.

m) F13 : Moment de différence inverse (IDM) [25]

$$\text{IDM} = \sum_{i,j} \frac{p(i,j)}{1+(i+j)^2} \quad (3.18)$$

IDM (Inverse Difference Moment), mesure l'homogénéité locale d'une image.

III.1.4.4 Phase de classification par SVM (Support Vector Machines)

En vue d'une classification de la tumeur présente dans une image IRM et après avoir réalisé l'opération de l'extraction des caractéristique en construisant le vecteur des caractéristique : $\mathbf{V_car} = [\mathbf{F1 F2 F3 F4 F5 F6 F7 F8 F9 F10 F11 F12 F13}]$, nous avons choisis un classifieur afin d'identifier les deux classes auxquelles appartiennent les tumeurs sui sont présentes dans les images IRM que nous avons utilisés et cela grâce à certains paramètres descriptifs. Notre choix sur le classifieur c'est porter sur les SVM qui est une méthode de classification binaire par apprentissage supervisé.

➤ **Principe de la technique SVM [21]**

Cette technique est une méthode de classification à deux classes qui tente de séparer. La méthode cherche alors l'hyperplan qui sépare les deux classes (**Tumeur Bénigne** et **Tumeur Maligne**), en garantissant que la marge entre le point de donnés le plus proche des deux classes soit maximale. L'intérêt de cette méthode est la sélection de vecteurs supports qui représentent les vecteurs discriminant grâce auxquels est déterminé l'hyperplan.

La figure III.11 représente l'interpolation géométrique des SVM linéaires. Ici, les hyperplans H1, H2, H3 sont utilisés pour classer les points de données en deux classes. L'hyperplan H1 a une grande marge aux vecteurs de support S11, S12, S13, S21, S22 et S23, donc il peut conduire vers une classification parfaite. Mais H2 et H3 ne peuvent pas réaliser une bonne classification car ils n'ont pas la plus grande marge.

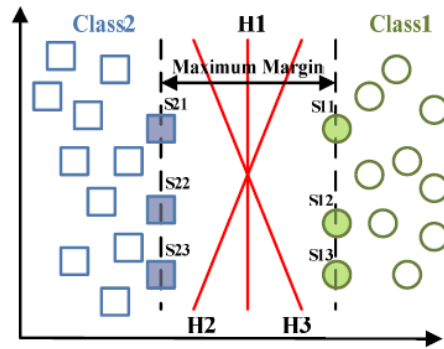


Figure III.11: L'interpolation géométrique des SVM linéaires (H désigne l'hyperplan, S désigne le vecteur de support).

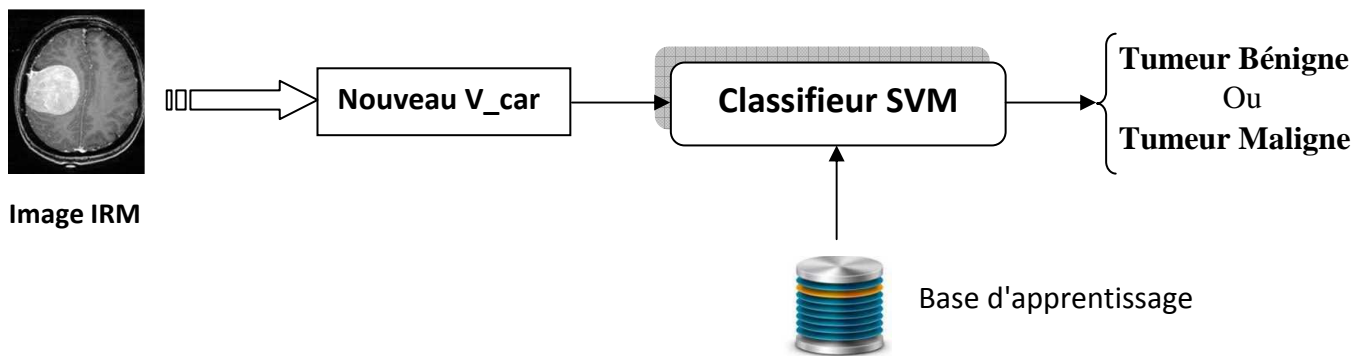


Figure III.12: Phase de classification de la tumeur par les SVM.

III.2 Résultats et discussion

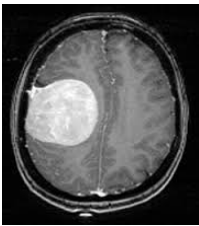
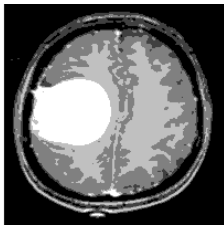
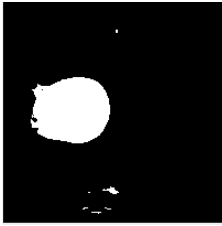

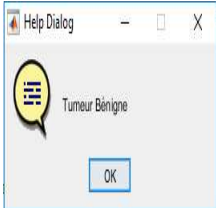

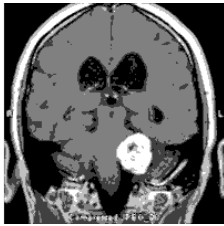

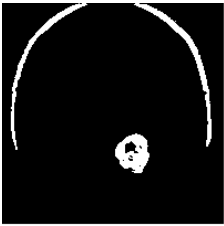

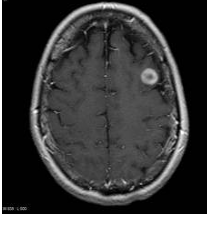
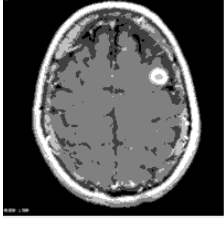
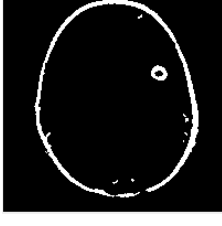
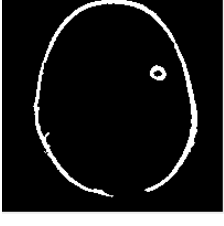
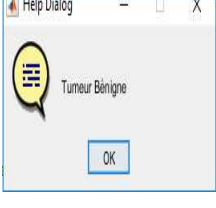
Dans notre expérience, nous avons sélectionné 20 images (10 bénignes et 10 malignes) sur lesquelles nous avons appliqué toutes les étapes précédentes afin de classer la tumeur obtenue en segmentant l'image IRM originale par l'ARKFCM.


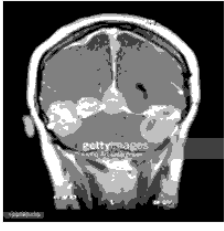


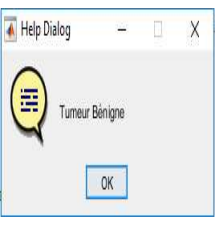

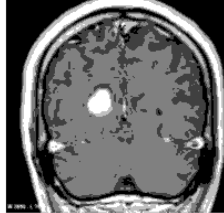
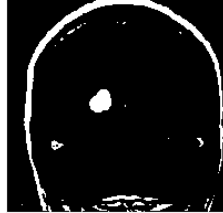

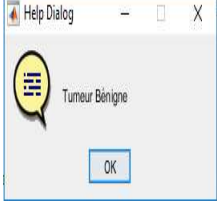
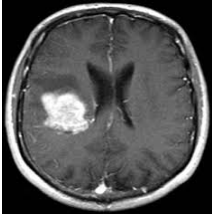
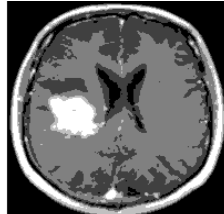
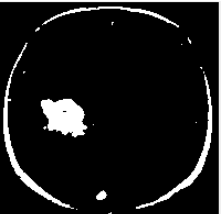
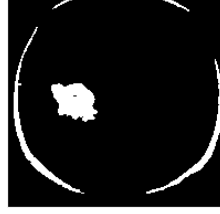
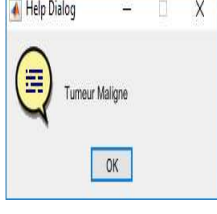
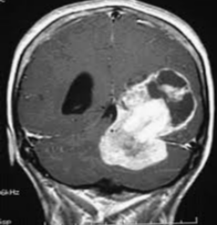
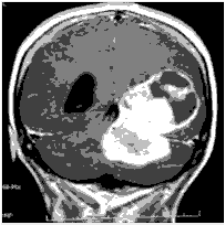




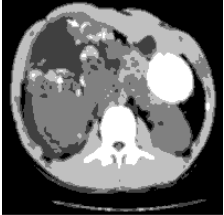

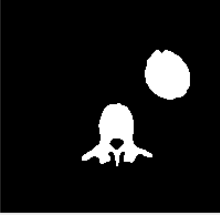

Le tableau suivant montre les résultats obtenus après chaque opération ;

- La première colonne présente les images originales qui sont les images IRM contenant la tumeur suivi de son indice (bénigne ou maligne).

Chapitre III: Détection et classification d'une tumeur cérébrale

- La deuxième colonne représente les images segmentées. La méthode d'ARKFCM est utilisée ici, ce qui est une méthode plus utile.
- La troisième colonne présente les tumeurs extraite avant l'application des opérations morphologique.
- La quatrième colonne présente les tumeurs extraite après l'application des opérations morphologique qui consiste à supprimer les objets inutile de petites tailles.
- La cinquième colonne présente les résultats finals de la classification SVM de la tumeur qui indique si cette dernière est maligne ou bénigne.

Type de Tumeur	Image segmenté (ARKFCM)	Tumeur extraite avant opérations morphologique	Tumeur extraite après opérations morphologique	Résultats de classification par les SVM	
Bénigne					
Bénigne					
Bénigne					

<p>Bénigne</p> 				
<p>Bénigne</p> 				
<p>Maligne</p> 				
<p>Maligne</p> 				
<p>Maligne</p> 				


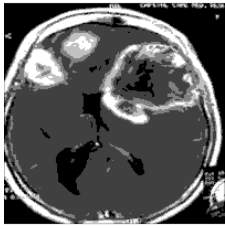



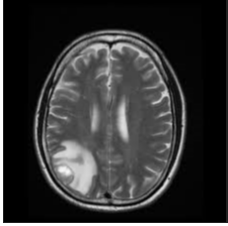
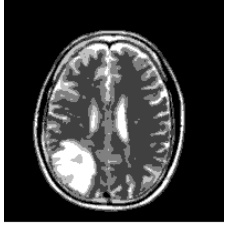


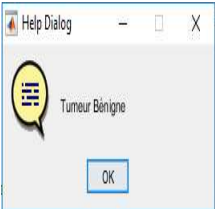
<p>Maligne</p> 				
<p>Maligne</p> 				

Tableau III.1 : Résultats de la classification des tumeurs présentes dans les images IRM.

- **Discussion**

D'après les résultats obtenus, nous pouvons dire que la méthode ARKFCM donne une bonne segmentation des images IRM cérébrales. Nous avons remarqué que la partie tumorale est correctement détectée car l'application de cette méthode facilite la détection des régions d'intérêts (la région tumorale).

Et aussi cette partie tumorale est bien localiser et elle est bien claire et ça dus a la combinaison des résultats trouvés par la segmentation ARKFCM avec les opérateurs morphologiques (remplissage des trous, suppression des régions qui sont aux bords de l'image, suppression des régions de trop petites tailles dans l'image, suppression des objets inutiles).

Après l'extraction de la tumeur, nous constatons que 80% ont été bien classifié tel que dans la classification concernant la tumeur bénigne nous avons abouti à 90% sur les 5 images utilisée, le taux est correct à 100% et pour la tumeur maligne, nous avons 3 sur 5 images ont été bien classé.

Sur l'ensemble de la base de données utilisées et qui contient 20 images, le tableau suivant illustre les résultats obtenus:

Classification	Bénigne	Maligne
20 images	9/10	6/10
Taux de classification (%)	90%	60%

Tableau III.2 : Taux de classification.

III.3 Conclusion

La tumeur cérébrale est une cause majeure de décès. De nombreuses techniques sont utilisées pour détecter la tumeur, le système proposé dans ce chapitre suit une approche dans laquelle nous avons d'abord appliqué une segmentation en se basant sur le ARKFCM comme algorithme de segmentation afin d'extraire la tumeur. Grâce à l'extraction de quelques caractéristiques (13) de cette dernière et en utilisant une base d'apprentissage combinée à un classifieur SVM linéaires, nous avons réalisé une classification de ces tumeurs présentes dans les images IRM en deux classes à savoir ; **Tumeur Bénigne** et **Tumeur Maligne**.

A partir des résultats obtenus, nous constatons que le système proposé arrive à réaliser une classification satisfaisante.

Conclusion générale

Le cerveau constitue l'un des organes les plus importants du corps humain. Les frontières physiques entre ses structures sont, même pour un œil averti, délicates à définir. D'innombrables pathologies peuvent l'endommager, ce qui résulte en une multitude de conséquences suivant les régions atteintes. L'IRM est l'une des techniques les plus récentes basée sur le phénomène de résonance magnétique nucléaire, elle permet d'offrir aux médecins une image complète sur le cerveau d'un sujet donné tout en étant non invasive et non douloureuse. Mais cette technique fournit des données imparfaites, entachées d'imprécisions et d'incertitudes; ses principaux défauts relevés sont, en particulier, liés au bruit (bruit d'acquisition, aux mouvements du patient...).

Le recours à des méthodes d'analyse plus automatisées peut être d'un grand intérêt pour un médecin comme outil d'aide au diagnostic. La segmentation constitue une étape clé dans la plupart des systèmes de traitement des IRM cérébrales dans la traque des pathologies cérébrales.

Pour notre travail dont l'objectif est la classification d'une tumeur au niveau du cerveau, nous avons utilisé l'algorithme ARKFCM en première phase afin de segmenter une image IRM ayant une tumeur au niveau du cerveau puis nous avons procédé à l'extraction de l'ensemble des classes (matière blanche MB, matière grise MG, liquide céphalo-rachidien LCR et la tumeur) contenues dans l'image IRM choisie. Le choix de cet algorithme est justifié par sa simplicité, son efficacité et sa robustesse vis-à-vis le bruit.

Les résultats expérimentaux montrent que l'algorithme ARKFCM donne des résultats assez satisfaisants et surpasse les autres algorithmes (FCM et ses variantes), en particulier, en présence du bruit. Les comparaisons quantitatives des algorithmes confirment l'évaluation visuelle.

Après avoir réalisé l'opération de l'extraction des caractéristiques en construisant le vecteur des caractéristique (contenant 13 caractéristiques), nous avons choisis un classifieur afin d'identifier les deux classes auxquelles appartiennent les tumeurs qui sont présentes dans les images IRM que nous avons utilisé et cela grâce à certains paramètres descriptifs. Notre choix sur le classifieur c'est porter sur les SVM qui est une méthode de classification binaire par apprentissage supervisé.

A la lumière de ce qui a été fait, l'objectif préliminaire a été en substance atteint. Mais en outre, des idées futures se dessinent :

- Surpasser le problème d'initialisation, vu que les approches de segmentation étudiées dans ce manuscrit demandent toujours l'intervention de l'être humain comme lors de la précision du nombre de classes en estimant ce dernier.
- L'automatisation de l'extraction de la tumeur (région d'intérêt) en se basant sur certaines caractéristiques discriminatives comme la surface de la tumeur.

Bibliographie

- [1] Nadia M'hamd Bouloudani, "Utilisation des Critères de Performance pour la Segmentation Automatique des Images Cytologiques Couleur", Mémoire de Magister, École Nationale Supérieure Polytechnique d'Alger, 2009.
- [2] M. Andre, Introduction aux techniques de traitement d'image, Eyrolles 1987.
- [3] EMMANUEL Tonye et LAIN Akono, Traitement des images de télédétection par l'exemple 2000, NDRE NDI Nyongui.
- [4] N. Nasri, "Segmentation d'images IRM", mémoire de Magister, université A. Mira Bejaia 30/05/2010.
- [5] J.-P.COCQUEREZ et S.PHILIPP, "Analyse d'images : filtrage et segmentation ", page3 - 266, Paris, (février 2003).
- [6] B. Sara et Ben. Sara "Méthode coopérative pour la segmentation d'images IRM cérébrales basée sur les techniques FCM et LEVEL SET", mémoire de Master, Université Abou Bekr Belkaid Tlemcen, 2012.
- [7] J. B. MacQueen, "Some Methods for classification and Analysis of Multivariate Observations, Proceedings of 5-th Berkeley Symposium on Mathematical Statistics and Probability", Berkeley, University of California Press, 1971.
- [8] A. Nawel, C. Lilia, Mémoire de fin d'études, "Une plateforme évolutive pour le développement d'approches biomimétiques en segmentation d'images", Ecole nationale Supérieure d'Informatique (ESI) Oued-Smar, Alger, 2009.
- [9] E. Luzárraga, M. Pacheco, "Segmentation automatique d'images IRM anténatales", Thèse de Fin d'études, Télécom PARIS-TECH, 27 juin 2013.
- [10] A. Mekhmoukh, Nasri, " algorithme fcm modifie pour la segmentation d'image bruitées".
- [11] A. Ouargla, "classification Floue des images", thèse doctorat, université de Batna, 14/12/2013.
- [12] A. Mekhmoukh "segmentation d'image IRM par améliorations de l'algorithme FCM ", thèse doctorat, université A. Mira Bejaia, 30/01/2016.

- [13] A. Nabila et B.Amina, "méthode coopérative pour la segmentation d'image : Application à l'imagerie médicale ", université A. Mira Bejaia, 2016.
- [14] E. Ahmed, W. Guangglin and H. Qingmaro, "segmentation of brain Tissues from magnetic resonance Images using adaptively regularized kernel-based fuzzy c-means clustering, research article, volume 2015, article ID 485495, 12page.
- [15] A. Tinhinane, B. Fatima "segmentation d'image par classification floue Application à l'image par résonance magnétique IRM ", mémoire master, université A. Mira Bejaia, 2015.
- [16] Zadeh, "Fuzzy sets" information and control, vol.8, pp.338-353, 1965.
- [17] A. Elazab, C.Wang, F. Jia, J. Wu, G. Li, and Q. Hu, "Segmentation of Brain Tissues from Magnetic Resonance Images Using Adaptively Regularized Kernel-Based Fuzzy C-Means Clustering", Vol 2015, Article ID 485495, 12 pages.
- [18] S. Miri, "Segmentation des structures cérébrales en IRM : intégration de contraintes topologiques", Rapport de stage, Université Louis Pasteur Strasbourg, 2007.
- [19] Zeggaikhaira & Zabouchi Aoumria "Segmentation des images IRM de cerveau et reconstruction 3D "Faculté de Technologie, Université Aboubekr Belkaid, Tlemcen, département de Génie Bio Médicale, projet de fin d'étude pour l'obtention du Diplôme de Master ,2012.
- [20] B. Khalida & S. Bilal, "Segmentation des gliomes bas grades sur des images IRM par une méthode statistique locale", mémoire master, université A. Mira Bejaia, 2016.
- [21] Y. Zhang, L. Wu, "An mr brain images classifier via principal component analysis and kernel support vector machine",Progress In ElectromagneticsResearch, Vol. 130, 369-388, 2012.
- [22] Haralick, R. M., K.Shanmugam, and I. H. Dinstein, 1973: Textural features for image classification. IEEE Transactions on Systems, Man and Cybernetics, 6, 610–621.
- [23] W. Gomez, W. C. A. Pereira and A. F. C. Infantosi, "Analysis of Co-Occurrence Texture Statistics as a Function of Gray-Level Quantization for Classifying Breast Ultrasound" IEEE Transactions on Medical Imaging, vol. 31, pp. 1889-1899, Oct. 2012.
- [24] M. IGGANE, D. MAMMASS, A. KHENCHAF and Jean-Christophe CEXUS, "Segmentation d'images sonar par matrice de cooccurrence", TUNISIA, 2009.
- [25] N.Loewke, "Haralick Texture Analysis for Stem Cell Identification", ed: Stan ford photonics Research center. Class Project. Poster, 2013.

Sites Web

- [26] <http://www.tsi.enst.fr/tsi/enseignement/ressources/mti/hystedyn/node2.html/algorithmes/>. Consulté le 26.03.2018.
- [27] http://www.chuv.ch/neurochir/nch_home/nch_activites_cliniques/nch_interventions_adultes/nch_tumeurs_adultes.html. Consulté le 17/05/2018.
- [28] [http://fr.wikipedia.org/wiki/Imagerie_par_résonance magnétique/](http://fr.wikipedia.org/wiki/Imagerie_par_r%C3%A9sonance_magn%C3%A9tique/). Consulté le 06/05/2018.

Résumé

La tumeur cérébrale est une maladie mortelle qui ne peut pas être détectée avec certitude sans IRM. Dans ce projet, il est tenté de classifier si une tumeur qui est déjà présente au niveau du cerveau du patient est bénigne ou maligne en utilisant MATLAB.

Pour ouvrir la voie à cette classification, l'image IRM a été d'abord segmentée par l'algorithme ARKFCM afin d'extraire la région d'intérêt qui est la tumeur, puis sur cette image segmentée, des opérations morphologiques ont été appliquées afin d'éclaircir mieux cette partie en éliminant les régions inutiles, ensuite viennent les étapes de la transformée en ondelette (DWT) suivie de l'application de l'analyse des composantes principales (ACP) et l'extraction des propriétés caractéristiques de la tumeur en utilisant les caractéristiques de Haralick.

Enfin la technique de classification par le SVM est utilisée pour la classification de la tumeur comme bénigne ou maligne, ce dernier a l'avantage utile de la haute précision. Et c'est ce qui s'avère d'après les résultats obtenus.

Mots clés: la segmentation ARKFCM, Image IRM, DWT, ACP, SVM, la classification de la tumeur, la tumeur bénigne et maligne.

Abstract

Brain tumor is a fatal disease that cannot be confidently detected without MRI. In this project, it is attempted to classify whether a tumor that is already present in the patient's brain is benign or malignant using MATLAB.

To pave the way for this classification, the MRI image was first segmented by the ARKFCM algorithm to extract the region of interest that is the tumor, and then on this segmented image, morphological operations were applied to to better clarify this part by eliminating unnecessary regions, then come the steps of the wavelet transform (DWT) followed by the application of the principal component analysis (PCA) and the extraction of the characteristic properties of the tumor in using the characteristics of Haralick.

Finally the SVM classification technique is used for the classification of the tumor as benign or malignant, it has the useful advantage of high precision. And that's what the results show.

Key-Words: ARKFCM segmentation, MRI, DWT, PCA, SVM, tumor classification, malignant and benign tumor.