

République Algérienne Démocratique et populaire
Ministère de l'Enseignement Supérieur et de la Recherche
scientifique
Université Abderrahmane Mira Béjaïa

Faculté de Technologie
Département ATE

Projet de fin d'études

En vue de l'obtention du diplôme Master

Filière : Télécommunication

Option : Système de Télécommunication

Thème :

Segmentation et classification d'image :
Application à l'Imagerie par Résonance
Magnétique (IRM)

Présenté par :

Melle IBRAHIM Dyhia et Melle SAOU Hania

Encadré par :

Mr.MEKHMOUK Abdenour

Membres de jury :

Mr.ALLICHE.A

Mr.MOKRANL.K

Promotion :2020

Remerciement

Avant tout, nous tenons à remercier ALLAH qui nous a donné l'aide, le pouvoir et la patience pour finaliser ce mémoire. Nous remercions les membres De jury qui ont acceptés D'évaluer ce travail.

Nous exprimons notre profonde gratitude à notre encadreur Mr. MEKHMOUKH Abdenour pour ces conseils et orientations tout au long d'élaboration de ce travail et pour son aide précieuse. ainsi qu'à tous nos professeurs De Département D'ATE De l'université Abderrahmane Mira de Béjaia qui ont contribués à notre formation.

Nous tenons également à remercier les examinateurs Mr. ALLICHE Abdenour et Mr. MOKRANI pour l'honneur qu'ils nous font en participant à l'évaluation de ce travail.

Nos remerciements à nos parents pour leur soutien. Aussi, nous tenons à remercier nos collègues et nos amis pour leurs encouragements et à toute la promotion Master 2.

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

Dédicaces

*Je dédie ce modeste travail
A ma chère mère
Pour son grand amour, ses sacrifices et toute l'affection qu'elle
m'a toujours offerte.
A mon cher père
Pour sa patience et ses considérables sacrifices pour me parvenir
à ce niveau.
A mes frères (Akli, khalef), mes sœurs (Zahra, Kahina, Djohra)
A mes chers amis
Ceux de l'université et ceux d'ailleurs,
A mes très chères copines (Aicha, Liza, Kenza, Myassa)
A tous ceux qui m'aiment et qui ont cru en moi !
Qu'ils trouvent dans ce modeste travail l'expression de ma
reconnaissance, mon amour, mon amitié et mon estime.*

Saou Hanina



Dédicaces

*Je dédie ce modeste travail
A ma chère mère
Pour son grand amour, ses sacrifices et toute l'affection qu'elle
m'a toujours offerte.
A mon cher père
Pour sa patience et ses considérables sacrifices pour me parvenir
à ce niveau.
A mon frère (Teyeb), mes sœurs (Linda et Sarah)
A mes tantes (Fatiha, Fatma, Karima, Ourdia)
A mes chers amis de la salle de l'enture et ceux d'ailleurs,
A mes chères amies (Sylia, Malika, Aldjia, Aicha, Kenza et
Myassa)
A ma chère Salima pour son aide et conseils
Et a mon oncle Abdenour pour tous ce qu'il a fait pour moi
A tous ceux qui m'aiment et qui ont cru en moi !
Qu'ils trouvent dans ce modeste travail l'expression de ma
reconnaissance, mon amour, mon amitié et mon estime.*

Abrahim

Dyhia



Liste des figures

Figure I.1: Une image cérébrale avec son histogramme	04
Figure I.2: chaîne de segmentation d'image	04
Figure I.3: différentes approches de la segmentation	07
Figure II.1: principe de classification	10
Figure II.2: Voisinage d'un pixel	17
Figure II.3: Image synthétique utilisée pour les tests	18
Figure II.4: Image segmentée pour K-Means, pour K=3	19
Figure II.5: Image segmentée pour K-Means, pour K=4	19
Figure II.6: Image segmentée pour K-Means, pour K=5	19
Figure II.7: Image segmentée pour FCM, pour K=3	20
Figure II.8: Image segmentée pour FCM, pour K=4	20
Figure II.9: Image segmentée pour FCM, pour K=5	20
Figure II.10: Image segmentée pour FCM-S1, pour K=3	21
Figure II.11: Image segmentée pour FCM-S1, pour K=4	21
Figure II.12: Image segmentée pour FCM-S1, pour K=5	21
Figure II.13: Image segmentée pour FCM-S2, pour K=3	22
Figure II.14: Image segmentée pour FCM-S2, pour K=4	22
Figure II.15: Image segmentée pour FCM-S2, pour K=5	22
Figure II.16: image synthétique bruitée avec bruit gaussien	23
Figure II.17: Résultats de la segmentation avec un bruit gaussien	24
Figure II.18: image synthétique bruitée avec le bruit Salt & Pepper	24
Figure II.19: Résultats de la segmentation avec un bruit Salt & Pepper	24
Figure III.1: L'encéphale	27
Figure III.2: Structure générale d'un cerveau humain	28
Figure III.3: Circulation du liquide céphalo-rachidien	30
Figure III.4: Coupe de cerveau avec les trois matières principales	31
Figure III.5: Présence d'une tumeur	32
Figure III.6: Salle d'imagerie par résonance magnétique	33
Figure III.7: Les trois axes de coupe pour la visualisation du cerveau	34
Figure III.8: Coupes IRM du cerveau : plan axial, coronal et sagittal (de gauche à droite).....	34
Figure III.9: Image cérébrale de coupe 96	35
Figure III.10: Résultat de la segmentation par les K-Means	36
Figure III.11: Résultat de la segmentation par les FCM	36

Liste des figures

Figure III.12: Résultat de la segmentation par les FCM-S1	37
Figure III.13: Résultats de la segmentation par les FCM-S2	37
Figure III.14: Résultat de la segmentation par les K-Means d'une image avec un bruit Gaussien	38
Figure III.15: Résultat de la segmentation par le FCM d'une image avec un bruit Gaussien	39
Figure III.16: Résultat de la segmentation par le FCM-S1 d'une image avec un bruit Gaussien	39
Figure III.17: Résultat de la segmentation par le FCM-S2 d'une image avec un bruit Gaussien	39
Figure III.18 : Résultat de la segmentation par les K-means d'une image bruitée avec Salt & Pepper	40
Figure III.19: Résultat de la segmentation par les FCM d'une image bruitée avec Salt & Pepper	40
Figure III.20: Résultat de la segmentation par les FCM-S1 d'une image bruitée avec Salt & Pepper	41
Figure III.21: Résultat de la segmentation par les FCM-S2 d'une image bruitée avec Salt & Pepper	41
Figure III.22 : Processus de classification	44
Figure III.23 : Extraction de la classe tumeur d'une image segmentée avec FCMS2	46
Figure III.24: Résultat de l'opération morphologique sur la tumeur	46
Figure III.25: Processus d'extraction des caractéristiques de la tumeur	47
Figure III.26: Arbre de décomposition niveau 3	48
Figure III.27: Transformée en ondelettes discrète s'applique à une image	48
Figure III.28: L'interpolation géométrique des SVM linéaires.....	52
Figure III.29: Phase de classification de la tumeur par les SVM	52

Liste des tableaux

Tableau III.1: Résultats obtenus pour les algorithmes K-Means, FCM, FCM-S1, FCM-S2, sans bruit et avec bruit. (Indice de Jaccard)	42
Tableau III.2 : Résultats obtenus pour les algorithmes K-Means, FCM, FCM-S1, FCM-S2, sans bruit et avec bruit. (Indice de Dice)	43
Tableau III.3: Résultats de la classification des tumeurs	57
Tableau III.4: Taux de classification	57

Liste des algorithmes

Algorithme 1: Algorithme des K-Means	12
Algorithme 2: Algorithme général d'exécution du FCM	15
Algorithme 3: Algorithme général d'exécution du FCM-S1	17

Liste des abréviations

IRM : Imagerie par Résonance Magnétique.

FCM: Fuzzy C-Means

FCM-S: Fuzzy C-Means Spatial

MB: Matière Blanche

MG: Matière Grise

LCR: Liquide Céphalo-Rachidien

RMN: Résonance Magnétique Nucléaire

PCA: Principal Component Analysis

DWT: Discrete Wavelet Transform.

SVM: Support Vector Machines.

GLCM: Gray Level Co-occurrence Matrix.

RMS: Root Mean Square.

IDM: Inverse Difference Moment.

Sommaire

Introduction générale.....	1
Chapitre I	
I.1. Introduction :.....	3
I.2. Définition d'une image :.....	3
I.3. Image numérique :.....	3
I.4. Image a niveau de gris :.....	3
I.5. Histogramme :.....	4
I.6. Chaîne de traitement d'image :.....	4
I.7. Définition de la segmentation d'image :.....	5
I.8. Différente approche de la segmentation :.....	6
I.8.1. Approche contour :.....	7
I.8.2. Approche région :.....	7
Chapitre II	
II.1. Introduction :.....	9
II.2. Classification pixel :.....	9
II.3. Principe de classification de pixels :.....	9
II.3.1. Méthodes supervisées :.....	10
II.3.2. Méthodes non supervisées :.....	11
II.4. Segmentation nette d'images par classification de pixels:.....	11
II.4.1. Segmentation par la méthode des K-Means :.....	11
II.4.1.1. L'algorithme des K-Means :.....	12
II.4.1.2. Avantages et inconvénients du k-Means :.....	12
II.5. Segmentation floue d'images par classification de pixels :.....	13
II.5.1. C-Means (CM) :.....	13
II.5.2. Fuzzy C-Means (FCM) :.....	14
II.5.2.1. Algorithme du Fuzzy C-Means (FCM) :.....	15
II.5.2.2. Analyse de l'algorithme FCM :.....	16
II.5.3. Les C-moyennes floues avec contraintes spatiales FCM_S :.....	16
II.5.3.1. L'algorithme des FCM-S :.....	17
II.6. Résultats et discussions :.....	18
II.6.1. Choix de nombre de classes :.....	18
II.6.2. Immunité au bruit :.....	23
II.7. Conclusion :.....	25

Sommaire

Chapitre III

III.1 Introduction :	26
III.2 Anatomie cérébrale :	26
III.2.1 L'encéphale :	26
III.2.2 Le cerveau :	27
III.2.3 Cervelet :	28
III.2.4 Tronc cérébrale :	28
III.3 Les Tissus du cerveau :	29
III.3.1 Le liquide céphalo-rachidien :	29
III.3.2 La matière grise :	30
III.3.3 La matière blanche :	30
III.3.4 Les méninges :	31
III.3.5 Les tumeurs cérébrales :	32
III.3.6 Les tumeurs cérébrales bénignes :	32
III.3.7 Les tumeurs cérébrales malignes :	32
III.4 Imagerie par Résonance Magnétique (IRM) :	33
III.5 Observation du cerveau :	33
III.6 Etude et résultats :	35
III.6.1 Etude sans Bruit :	35
III.6.2 Segmentation d'une image IRM en présence d'un bruit :	38
III.7 Critère d'évaluation :	42
III.8 Processus de classification de la tumeur :	44
III.8.1 Opérations morphologique :	45
III.8.2 Extraction des caractéristiques :	46
III.8.2.1 Transformée en ondelettes discrète :	48
III.8.2.2 Matrice de cooccurrence :	49
III.9 Classification par SVM (Support Vector Machines) :	51
III.10 Résultats et discussion :	53
III.11 Conclusion :	58
Conclusion générale :	60

Introduction générale

Introduction générale

A partir des années soixante-dix, les chercheurs ont considéré que la première étape de traitement visuel chez l'homme et l'animal se fait nécessairement par réflexes. En effet, les entités, les formes et les contours émergent automatiquement chez l'individu, de façon inconsciente, indépendamment d'une connaissance à priori de l'environnement. Tout ceci a donné naissance à une discipline basée sur l'automatisation de cette faculté, qui est l'analyse d'image. L'analyse d'image ou le traitement d'image a pour but l'extraction de l'information caractéristique contenue dans une image.

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.

Le but de 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**.

Il existe plusieurs algorithmes de segmentation d'images, selon le cas à résoudre.

- Les méthodes de segmentation par contours basés sur la recherche des discontinuités locales présentés dans l'image.
- Les méthodes de segmentation en régions homogènes consistent à trouver des ensembles de pixels qui partagent des propriétés similaires. Les régions

Introduction générale

homogènes sont construites à partir des parties connexes de ses ensembles, les techniques le plus connus dans cette méthode, est la classification.

- Les méthodes de classification fournissent une partition de l'image en regroupant des pixels ayant des niveaux de gris similaires dans une même classe de pixels. Les régions sont définies par les ensembles maximaux de pixels connexes appartenant à la même classe.

En général, on peut les répartir en : méthodes supervisées qui se basent sur un modèle exacte, fourni par un expert, des classes à obtenir et les méthodes non supervisées où aucune connaissance à priori n'est disponible.

Dans ce mémoire nous nous intéresserons essentiellement à la segmentation par classification non supervisé qui ne nécessite pas des connaissances a priori, comme l'algorithme K-Means, Fuzzy C-Means (FCM) et Fuzzy C-Means Spatial (FCM-S).

Dans le premier chapitre, nous présentons des généralités sur le traitement d'image et la segmentation et ces différentes approches.

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 synthétiques et images IRM réelles après l'application des différentes variantes du FCM (FCM-S).

Ensuite, nous aborderons dans le troisième chapitre quelques généralités dans le domaine médical dont nous décrirons l'anatomie cérébrale et appliquer les méthodes décrites dans le second chapitre afin de segmenter des images cérébrales IRM et de réaliser une classification des différents tissus cérébraux, puis nous allons effectuer une classification des tumeurs **bénigne** ou **maligne**.

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

Chapitre I

I.1. Introduction :

Dans ce premier chapitre, nous allons décrire en premier lieu des notions de base sur l'image et quelque technique pour son traitement. En second lieu nous allons présenter la chaîne de traitement d'image ensuite une définition de la Segmentation d'image en analysant de manière plus précise les techniques du contour et les différentes approches de segmentation d'image en région.

I.2. Définition d'une image :

Une image est un cadre défini par un individu, elle peut être naturelle (ombre, reflet) ou artificielle (peinture, photographie).

Les images ont plusieurs sortes de rapport avec ce qu'elles représentent. Il y a celle qui entretiennent un rapport analogique avec leur sujet comme dans le cas des dessins et photographies car elle ressemble à leur sujet. Certaines représentations entretiennent un rapport direct avec leur sujet, mais sans ressemblance physique, comme dans le cas des organigrammes et schéma de montage électronique. D'autres cas d'image exagèrent les caractéristiques comme les caricatures [1].

I.3. Image numérique :

Les images de nos jours sont le plus souvent numériques ce qui veut dire que leur surface est divisée en très petits éléments manipulables de taille fixe appelés pixels. Et chaque pixel a comme caractéristique un niveau de gris ou de couleurs.

I.4. Image à niveau de gris :

Pour une image à niveau de gris chacun de ces pixels peut prendre des valeurs dans l'intervalle [0 255] allant du noir représenté par le '0' au blanc représenté par '255', en passant par tous les niveaux de gris.

I.5. Histogramme :

L'histogramme d'une image est une fonction de repartitions du nombre des pixels dans une image en fonction de leurs intensité, il représente le niveau de l'intensité dans l'axe des abscisses en allant du plus foncé (à gauche) au plus clair (à droite). Histogramme apporte des informations quantitatives mais ne contient aucune information spéciale [2].

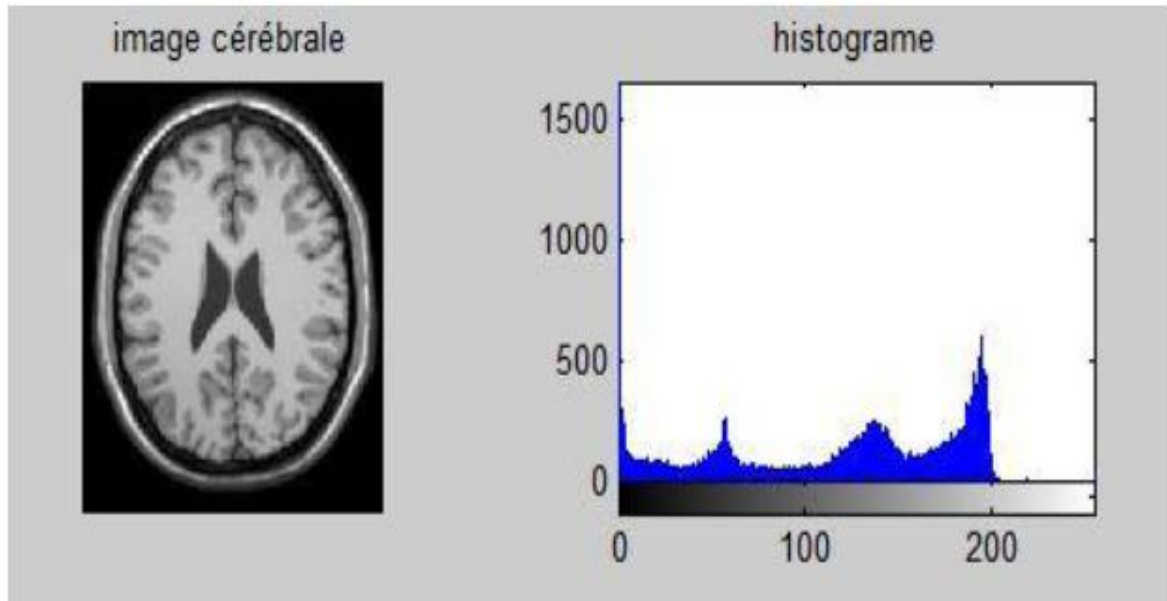


Figure I.1 : Une image cérébrale avec son histogramme [1].

I.6. Chaîne de traitement d'image : [3]

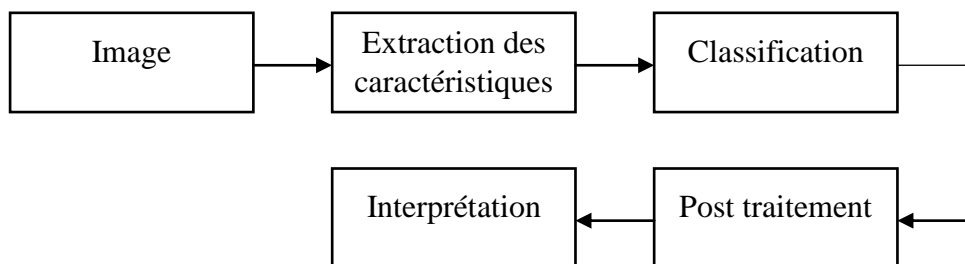


Figure I.2 : chaîne de segmentation d'image

- **Acquisition des images :**

Dans cette étape il est important d'avoir les même conditions d'acquisition pour toutes les images ce qui veut dire :

Chapitre I : Etat de l'art de la segmentation d'image

- Contrôler la lumière (pour chaque prise de vue).
- Bon éclairage qui réduit les reflets et les ombres.
- Avoir une résolution suffisante pour voir tous les détails.

- **Pré_ segmentation des images :**

Dans cette étape il faut réduire le bruit (due aux conditions d'acquisition) avec un filtre qui aidera à l'enlever.

- **Segmentation des images :**

Il faut avoir une seule méthode pour toutes les images. Il faut tenir compte que chaque algorithme de segmentation est très différent.

Un algorithme de segmentation seule n'est forcément efficace. Il faut combiner quelque fois plusieurs techniques.

- **Post_ traitement des images :**

En post de traitement on va corriger les erreurs de segmentation, étiqueter les régions et créer un masque pour les objets voulus.

I.7. Définition de la segmentation d'image :

La segmentation d'image est un traitement de bas niveau qui consiste à partitionner l'image A en sous-ensembles R_i appelés régions, de tels que chaque région doit avoir une homogénéité selon un critère prédéfini:

- $\forall i R_i \neq \emptyset$
- $\forall i, j ; i \neq j R_i \cap R_j = \emptyset$
- $A = \cup_i R_i$

Une région est un ensemble connexe de points image (pixels) ayant des propriétés communes (intensité, texture, ...) qui les différencient des pixels des régions voisines [4].

La segmentation est donc l'affectation des pixels à des régions homogènes et disjointes formant une partition de l'image. Les pixels qui appartiennent à la même région partagent une propriété commune dite critère d'homogénéité. Cependant, il est important de souligner que le nombre de régions est indéterminé et qu'il peut donc exister plusieurs segmentations pour un critère d'homogénéité donné (niveau de gris, la couleur, la texture ...) [5].

Chapitre I : Etat de l'art de la segmentation d'image

L'intérêt de ces régions est de pouvoir être manipulées ensuite via des traitements de haut niveau pour extraire des caractéristiques (forme, position, taille, ...). L'union des régions obtenues doit redonner l'image initiale [6].

I.8. Différente approche de la segmentation :

Il n'y a pas de méthode unique de segmentation d'une image, le choix d'une technique est lié [4] :

- **à la nature de l'image** : Eclairage non homogène, présence de bruit, contours flous.
- **aux opérations situées en aval de la segmentation** : localisation, mesure, calcul 3D, reconnaissance des formes, interprétations, diagnostic et contrôle de qualité.
- **aux primitives à extraire** : contours, régions ...etc.
- **aux contraintes d'exploitation** : complexité de l'algorithme, taille de la mémoire disponible en machine.

Du fait de cette diversité il est difficile de définir, de façon absolue, une bonne segmentation. De plus sa qualité se mesure aux résultats obtenus par les traitements situés en aval qui utilisent les primitives à extraire.

La segmentation fait référence aux notions de déférence et de similarité comme les perçoit le système visuel humain, et ceci donne naissance a deux approche couramment qualifier : l'approche contour et l'approche région.

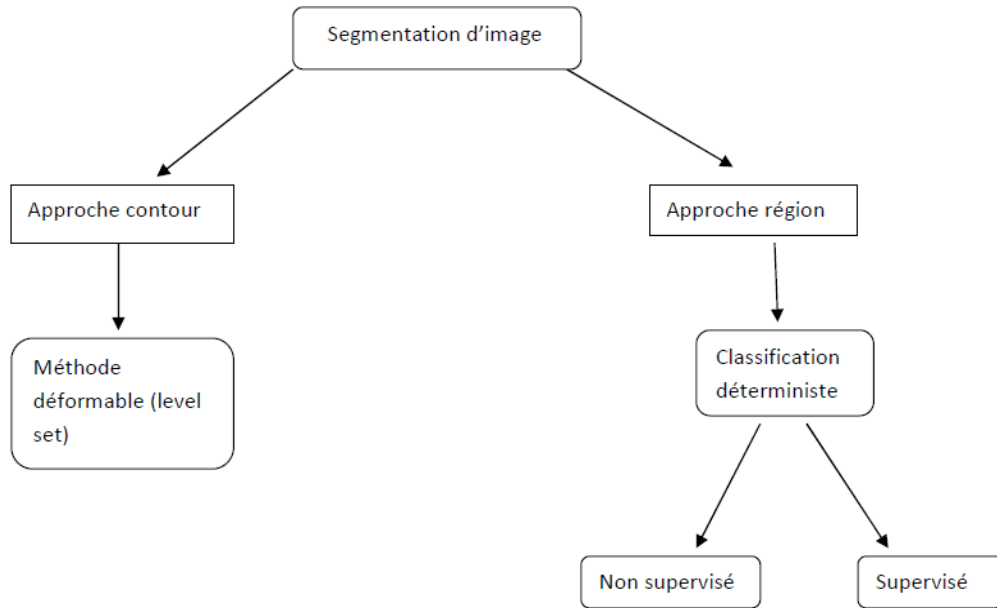


Figure I.3 : différentes approche de la segmentation [2].

I.8.1. Approche contour :

Les techniques des détections des contours sont des techniques bien développées de traitement de l'image, elle est basée sur le changement rapide de la valeur de l'intensité de lumière dans une image, car une seule valeur d'intensité ne fournit pas de bonnes informations sur les contours. Cette technique détecte le contour par deux(2) méthodes: soit la premières dériver de l'intensité est supérieurs a un certain seuil, soit la seconde dérivée a des passages par zéro.

Dans cette technique, tout d'abord les contours sont détectés, puis sont connectés ensemble pour former les limites d'objet a fin de segmenter les régions requise [7].

I.8.2. Approche région :

La méthode segmentation région consiste à segmenter l'image en plusieurs régions similaires.il existe deux(2) techniques basic [8]:

- Croissance région : méthodes croissance région de segmente l'image en plusieurs régions en faisant accroître chaque région autour d'un point de départ (pixel initial). Le pont de départ peut être sélectionné manuellement ou automatiquement.

Chapitre I : Etat de l'art de la segmentation d'image

- La croissance du point du départ est contre par in indicateur d'homogénéité entre pixels, lorsque cette indicateurs d'homogénéité est briser la croissance s'arrête [9].
- Méthode de décomposition et de fusion (Split & Merg) : la méthode de décomposition et de fusion utilise deux (2) techniques basic, c'est-à-dire décomposer et fusionner pour segmenter une image en plusieurs régions. Décomposition signifie la division interactive d'une image en régions ayant des caractéristiques similaires, et la fusion contribue a combiné er les régions similaires adjacentes [10].

Chapitre II

II.1. Introduction :

La segmentation est une des étapes primordiales de l'analyse d'images qui a pour but de regrouper les pixels entre eux suivant des critères prédéfinis aboutissant à une partition de l'image traitée. Ce chapitre vise à citer les diverses méthodes de la segmentation et de classification les plus connues et qui font référence à l'existence de groupes ou classes de données. Nous nous intéressons à des méthodes de classifications telles que K-Means et FCM dans laquelle est intégrée l'information spatiale voisine aux pixels d'intérêt. Ainsi, dans le but d'apprécier les approches contours, nous introduisons l'algorithme des levels sets et pour rendre cet algorithme robuste au bruit et rapide, nous avons implanté l'algorithme FCM-S, l'initialisation et les paramètres de contrôle de l'algorithme des levels sets sont estimés à partir du résultat de cette méthode.

II.2. Classification pixel :

La classification est une opération préalable à la segmentation; elle consiste à regrouper en classes les pixels de l'image ayant les caractéristiques colorimétriques similaires. Les classes sont formées à partir des attributs des pixels. Les classes doivent être aussi distinctes que possible les unes des autres [11]. Une région sera constituée de pixels d'une même classe mais il peut y avoir dans l'image plusieurs régions correspondant à une même classe [12].

La segmentation prendra fin par l'extraction des composantes connexes et que tous les pixels qui appartiennent à une même classe se voit attribuer une étiquette (valeur entière).

II.3. Principe de classification de pixels :

La problématique de la classification est de déterminer les procédures qui vont nous permettre de regrouper en une classe les pixels ayant des niveaux de gris similaires. La mise en œuvre d'une procédure de classification, ayant pour objectif de classifier automatiquement des objets comporte généralement deux phases fondamentales [13] :

- une phase d'apprentissage dont le but est de déterminer un espace de représentation des objets et de rechercher les paramètres discriminants capables de caractériser chaque classe d'objets.

chapitre II : Segmentation d'image par classification des pixels

– une phase de reconnaissance au cours de laquelle on attribue à une classe chacun des objets inconnus dans l'espace de représentation déterminé durant l'apprentissage.

La classification se décline essentiellement en deux grandes familles : la classification dite supervisée et la classification dite non supervisée (automatique).

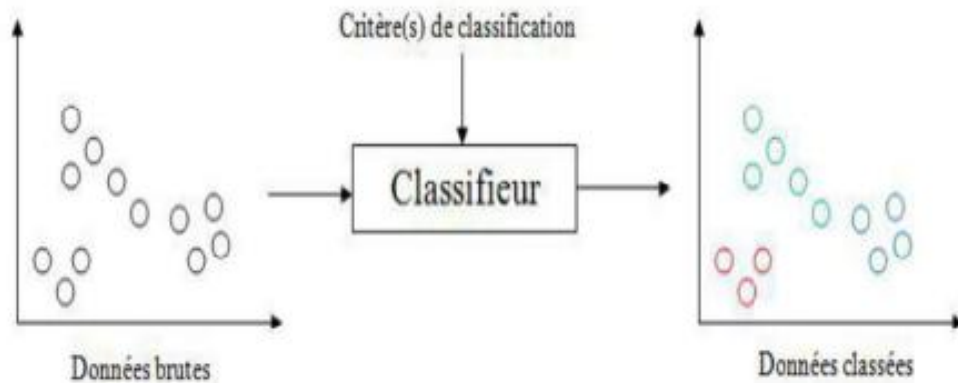


Figure II.1 : principe de classification [3].

II.3.1. Méthodes supervisées :

Les méthodes supervisées nécessitent un ensemble d'images ou de régions d'intérêt dans l'image déjà étiquetée. Soit, les données à analyser $X = \{x_j \in R^p, 1 \leq j \leq N\}$, où x_j est un vecteur forme représentant le pixel j . Cet ensemble de données est décomposé en deux sous ensembles : un ensemble d'apprentissage et un ensemble de test. L'ensemble d'apprentissage est construit par étiquetage manuel des images ou des régions d'intérêt en C classes de tissus (C_1, C_2, \dots, C_c) par un ou plusieurs experts. Chaque classe C_i se voit donc affecter un ensemble d'apprentissage E_i , et les données de l'ensemble de test sont segmentées en fonction des E_i . Parmi ces méthodes on peut citer : la segmentation Bayésienne, la segmentation par les champs de Markov, réseaux de neurones ... [13].

Pour notre cas, puisqu'il s'agit de segmenter des images médicales IRM cérébrales, la classification supervisée de ces images nécessite donc la création d'une base d'apprentissage pour chaque classe et pour chaque patient ce qui est en elle même une tâche très fastidieuse pour les experts [14]. C'est pour cela qu'on s'intéressera plus dans notre travail aux méthodes non supervisées.

chapitre II : Segmentation d'image par classification des pixels

II.3.2. Méthodes non supervisées :

L'intérêt des méthodes non supervisées est qu'elles ne nécessitent aucune base d'apprentissage et par là même aucune tâche préalable d'étiquetage manuel. La seule intervention de l'expert se situe à la fin du processus pour identifier les images.

Cette méthode permet de mettre dans le même groupe des éléments ayant propriétés similaire. Les algorithmes non supervisés les plus répandus tendent à minimiser une fonction objective, dépendant de la distance de chaque pixel aux centres des classes. Le centre d'une classe étant un point connu dont l'appartenance à la classe est garantie et où chaque pixel est assigné à la classe qui lui est la plus proche. Selon la certitude de la classification que nous voulons obtenir, et la relation entre les classes [13]. Nous pourrions distinguer plusieurs méthodes de classification comme la méthode des K-moyennes (*K-Means* en anglais) et l'algorithme des C-moyennes floues (*fuzzy C-Means* "FCM" en anglais) sur lesquelles nous nous sommes basés dans ce mémoire.

Dans ce type de classification le nombre de classes, inconnu a priori, est déduit directement des données.

II.4. Segmentation nette d'images par classification de pixels:

Les méthodes de classification permettent de regrouper des objets en groupes ou classes d'objets plus homogènes. Les objets regroupés ont des caractéristiques communes, ils sont similaires, mais se distinguent clairement des objets des autres classes. Les éléments classés sont les pixels de l'image qui nous permettent d'avoir des groupes. Généralement, les méthodes de classification conduisent à des résultats plus ou moins différents [15].

L'algorithme des K-Means est l'algorithme de classification utilisé, du fait de sa simplicité de mise en œuvre.

II.4.1. Segmentation par la méthode des K-Means :

L'algorithme des K-Means (K-moyennes) est une méthode statistique qui permet de répartir les données en groupes homogènes.

Il a comme but de rassembler les N points ou primitives dans C classes (clusters) dont le nombre est prédéterminé dans lesquelles chaque point ou primitive (ici dans notre cas pixel caractérisé par son niveau de gris) appartient à la classe avec la moyenne la plus proche [1].

chapitre II : Segmentation d'image par classification des pixels

Le K-Means est de minimiser la fonction objective :

$$J(X, V) = \sum_{i=1}^C \sum_{j=1}^N \|x_j - v_i\|^2 \quad (1)$$

- v_i : est le centre du cluster (classe) i
- $\| \cdot \|$: est la norme Euclidienne qui mesure la similarité entre un pixel est un autre

II.4.1.1. L'algorithme des K-Means :

L'algorithme suivant résume les étapes principales pour l'exécution :

Algorithme 1 : Algorithme des K-Means

Étape 1 : Choisir aléatoirement les C centres initiaux $v_1; v_2, \dots, v_c$ à partir des Points $\{x_1; x_2, \dots, x_N\}$.

Étape 2 : Assigner $x_j, j = 1, 2, \dots, N$ au cluster $Z_i, i = 1, 2, \dots, C$

Si

$\|x_j - v_i\| \leq \|x_j - v_p\|, p = 1, 2, \dots, C$ avec $j \neq p$

Choix aléatoire si conflit

Étape 3 : Calculer les nouveaux centres $v_i^* = \frac{1}{n_i} \sum_{x_j \in Z_j} x_j, i = 1, 2, \dots, C$

n_i est le nombre d'éléments dans le cluster Z_i

répéter l'étape 2 et l'étape 3 jusqu'à ce que $v_i^* = v_i \forall i = 1, 2, \dots, C$.

II.4.1.2. Avantages et inconvénients du k-Means :

Nous citons ci-dessous quelque avantages et inconvénients de la méthode [12] :

Avantages :

- Apprentissage non supervisé : la méthode des k -moyennes et ses variantes ne nécessitent aucune information sur les données. La segmentation peut être utile, pour découvrir une structure cachée qui permettra d'améliorer les résultats de méthodes d'apprentissage supervisé (classification, estimation, prédiction).

- Applicable à tous type de données : en choisissant une bonne notion de distance, la méthode peut s'appliquer à tout type de données (mêmes textuelles).

Inconvénients :

- Problème du choix de la distance : les performances de la méthode (la qualité des groupes constitués) sont dépendantes du choix d'une bonne mesure de similarité ce qui est une tâche délicate surtout lorsque les données sont de types différents.
- Le choix des bons paramètres : la méthode est sensible au choix des bons paramètres, en particulier, le choix du nombre k de groupes à constituer. Un mauvais choix de k produit de mauvais résultats. Ce choix peut être fait en combinant différentes méthodes, mais la complexité de l'algorithme augmente.
- L'interprétation des résultats : il est difficile d'interpréter les résultats produits, en d'autres termes, d'attribuer une signification aux groupes constitués.

II.5. Segmentation floue d'images par classification de pixels :

Parfois il est délicat de décider si un pixel appartient à la classe a ou à classe b. Pour répondre à ce type de situation les méthodes de segmentation floue supposent que les pixels appartiennent plus ou moins à ces sous-ensembles et considèrent que les pixels peuvent ainsi être regroupés en sous-ensembles flous de pixels. Pour cela, ces méthodes sont basées sur les concepts de la logique floue [16].

Le point clé de la segmentation d'images par classification de pixels est la construction des classes de pixels en présence. Celle-ci s'appuie sur les concepts de la logique floue en considèrent les pixels comme des sous-ensembles flous. Les méthodes de construction des classes telles que les C-Means et les Fuzzy C-Means seront présentées dans ce qui suit.

II.5.1.C-Means (CM) :

Soit $E = \{x_1, x_2, \dots, x_n\}$ l'ensemble des échantillons de la base d'apprentissage. x_n est le n ème vecteur d'attribut x . Les ensembles des centres de classes sont $\{V_1, V_2, \dots, V_c\}$ ou C dénote le nombre de classe.

La méthode des C-moyennes floues a pour objectif de déterminer les centres des différentes classes, ainsi que les degrés d'appartenance de chaque pixel aux différentes classes.

Les centres des différentes classes sont déterminés de telle sorte que la distance d entre un centre de classe et les pixels appartenant à cette classe soit minimale. La fonction objective J est de la forme [17] :

$$J = \sum_{i=1}^c \sum_{j=1}^n \mu_{ij}(x) \|x_j - v_i\|^2 \quad (2)$$

Ou:

- μ_{ij} : est le degré d'appartenance de x_i dans le j ème classe
- v_i : est le centre du cluster (classe) i

II.5.2.Fuzzy C-Means (FCM) :

Le Fuzzy C-Means est un algorithme de classification non supervisées qui peut être appliqué a plusieurs problèmes comprenant l'analyse des caractéristiques, la classification, le diagnostic médical et la segmentation d'image [18]. L'algorithme du FCM à été proposer par Bezdek et.al, il permet à un objet de données d'appartenir à deux ou plusieurs classes.

Il est basé sur la minimisation de la fonction objective suivante :

$$J_m(U, V) = \sum_{i=1}^c \sum_{j=1}^n \mu_{ij}^m(x) \|x_j - v_i\|^2 \quad 1 \leq m < \infty \quad (3)$$

Avec

$$\sum_{i=1}^c \mu_{ij} = 1, \mu_{ij} \in [0, 1] \quad , \quad 1 \leq j \leq N, 1 \leq i \leq C \quad (4)$$

- $m(> 1)$: est le paramètre qui contrôle le degré du flou
- μ_{ij} : est le degré d'appartenance de x_i dans le j ème classe
- x_i : est l' i ème élément des données mesurées
- v_i : est le centre du cluster (classe) i
- $\| \cdot \|$: est la norme Euclidienne qui mesure la similarité entre un pixel est un autre.

Les degrés et les centres d'appartenance sont, pour une valeur de N donnée, calculés à l'aide des deux formules suivantes :

$$\mu_{ij} = \sum_{k=1}^c \left(\frac{\|x_j - v_i\|}{\|x_j - v_k\|} \right)^{\frac{-2}{m-1}} \quad (5)$$

$$V_i = \frac{\sum_{j=1}^n (\mu_{ij})^m x_j}{\sum_{j=1}^n (\mu_{ij})^m} \quad (6)$$

Le test d'arrêt au temps $t + 1$ est donné par la différence $|J_m^{t+1} - J_m^t| < \text{seuil}$

II.5.2.1. Algorithme du Fuzzy C-Means (FCM) :

L'algorithme suivant résume les étapes principales pour l'exécution :

Algorithme 2 : Algorithme général d'exécution du FCM

Étape 1 :

- Choisir le nombre de classes : C
- Fixer m , $1 < m < \infty$
- Choisir ε pour le test d'arrêt.
- Initialiser ($t = 0$) la matrice de partition $U^{t=0}$ des fonctions d'appartenance à des valeurs aléatoires ou bien en leur affectant comme valeur $\frac{1}{c}$
- on met par exemple $d_{ij} = \|x_i - c_j\|$

Étape 2 : Calculer le vecteur C-Mean V_i des centres en utilisant l'équation (U_{ij})

Étape 3 : Mettre à jour U^t en utilisant :

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

Étape 4 : Comparer J^{t+1} à J^t si $|J_m^{t+1} - J_m^t| < \varepsilon$ alors arrêt sinon $t = t+1$ et retourner à l'étape 2.

II.5.2.2. Analyse de l'algorithme FCM :

L'algorithme est limité par le choix a priori des paramètres suivant [19] :

- Le nombre de classe qui est fourni à l'avance.
- L'initialisation aléatoire des paramètres.
- Le choix du prototype.
- Le paramètre de contrôle du flou (m).

II.5.3. Les C-moyennes floues avec contraintes spatiales FCM_S :

La fonction objective est donnée par :

$$J_m(U, V) = \sum_{i=1}^c \sum_{j=1}^n \mu_{ij}^m(x) \|x_j - v_i\|^2 + \alpha \sum_{i=1}^c \sum_{j=1}^n \mu_{ij}^m(x) \|\bar{x}_j - v_i\|^2 \quad (7)$$

Avec

$$\sum_{i=1}^c \mu_{ij} = 1, \mu_{ij} \in [0, 1], \quad 1 \leq j \leq N, 1 \leq i \leq c \quad (8)$$

Les centres des classes sont donnés par :

$$\mu_{ij} = \frac{(\|x_j - v_i\|^2 + \alpha \|\bar{x}_j - v_i\|^2)^{-1}}{\sum_{k=1}^c (\|x_j - v_k\|^2 + \alpha \|\bar{x}_j - v_k\|^2)^{-1}} \quad (9)$$

$$V_i = \frac{\sum_{j=1}^n (\mu_{ij})^m (x_j + \alpha \bar{x}_j)}{(1 + \alpha) \sum_{j=1}^n (\mu_{ij})^n} \quad (10)$$

- α : est un coefficient de pondération
- \bar{x}_j : est la moyenne des voisins dans une fenêtre spécifiée autour x_j de dont il représente le niveau de gris du même pixel de l'image moyenne \bar{X} de l'image originale X

chapitre II : Segmentation d'image par classification des pixels

Le calcul de la **moyenne** des voisins représentés par la fenêtre **3x3** donne la première variante de l'algorithme Spatial FCM appelé FCM_S1, et le calcul de la **médiane** des voisins donne la seconde variante FCM_S2 [12].




Figure II.2 : Voisinage d'un pixel [4].

II.5.3.1. L'algorithme des FCM-S :

L'algorithme suivant résume les étapes principales pour l'exécution :

Algorithme 3 : Algorithme général d'exécution du FCM-S1

Étape 1 :

- Choisir le nombre de classes : C
- Fixer m , $1 < m < \infty$
- Choisir ε pour le test d'arrêt.
- Initialiser ($t = 0$) la matrice de partition $U^{t=0}$ des fonctions d'appartenance à des valeurs aléatoires ou bien en leur affectant comme valeur $\frac{1}{c}$
- on met par exemple $d_{ij} = \|x_i - c_j\|$

Étape 2 : Calculer le vecteur C-mean V_i des centres en utilisant l'équation (U_{ij})

Étape 3 : Mettre à jour U^t en utilisant la médiane (\tilde{x}_j) pour FCM-S2 et la moyenne (\bar{j}) pour FCM-S1

$$\mu_{ij}^{t+1} = \frac{(\|x_j - v_i\|^2 + \alpha \|\bar{x}_j - v_i\|^2)^{\frac{-1}{m-1}}}{\sum_{k=1}^c (\|x_j - v_k\|^2 + \alpha \|\bar{x}_j - v_k\|^2)^{\frac{-1}{m-1}}}$$

Étape 4 : Comparer J^{t+1} à J^t si $|J_m^{t+1} - J_m^t| < \varepsilon$ alors arrêt sinon $t = t+1$ et retourner à l'étape 2.

II.6. Résultats et discussions :

Afin de retracer et comparer les différentes méthodes de segmentation décrites précédemment notamment leurs performances et leurs robustesses au bruit, nous les appliquons sur des images synthétiques, en fixant des paramètres qui contrôlent l'effet de la classification, le choix de ces derniers est d'une importance majeure, ces paramètres varient d'une image à une autre, ce qui rend difficile, la recherche de la valeur optimale de chaque paramètre. Pour ce travail, nous avons fixé les différents paramètres comme suit:

- Le degré de flou $m = 2$.
- Le critère d'arrêt $\varepsilon = 0.001$.
- Pour le FSM_S2 le coefficient de pondération $\alpha = 3$ et une fenêtre de 3X3.

Les tests ont été implémentés sous Matlab R2009b (7.9.0), et exécutés sur un PC (Intel® Pentium (R), [CPU2020M@2.40GHz](#)).

II.6.1. Choix de nombre de classes :

L'algorithme des **K-Means**, **FCM**, **FCM-S1** et **FCM-S2** laissent le paramètre de nombre de classes libre.

Pour voir l'influence du nombre K de classes, nous utiliserons l'image synthétique suivante, on fait varier le nombre K de classes.

Dans cette image on distingue 4 régions ($K=4$) de formes diverses.




Figure II.3 : Image synthétique utilisé pour les tests.

Après la segmentation pour différentes classes pour les différents programmes (K-means, FCM, FCM-S1, FCM-S2) nous avons trouvé les résultats suivants:

❖ K-Means :

- Pour $K=3$:




Figure II.4: Image segmenté avec K-Means, pour $K=3$.

- Pour $K=4$:




Figure II.5: Image segmenté avec K-Means, pour $K=4$.

- Pour $K=5$:

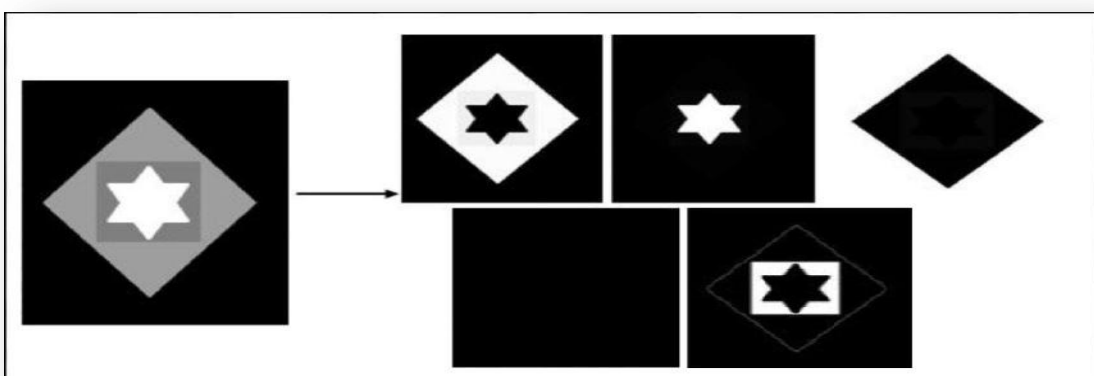


Figure II.6: Image segmenté avec K-Means, pour $K=5$.

- ❖ FCM :
 - Pour $K=3$:




Figure II.7: Image segmenté avec FCM, pour $K=3$.

- Pour $K=4$:




Figure II.8: Image segmenté avec FCM, pour $K=4$.

- Pour $K=5$:

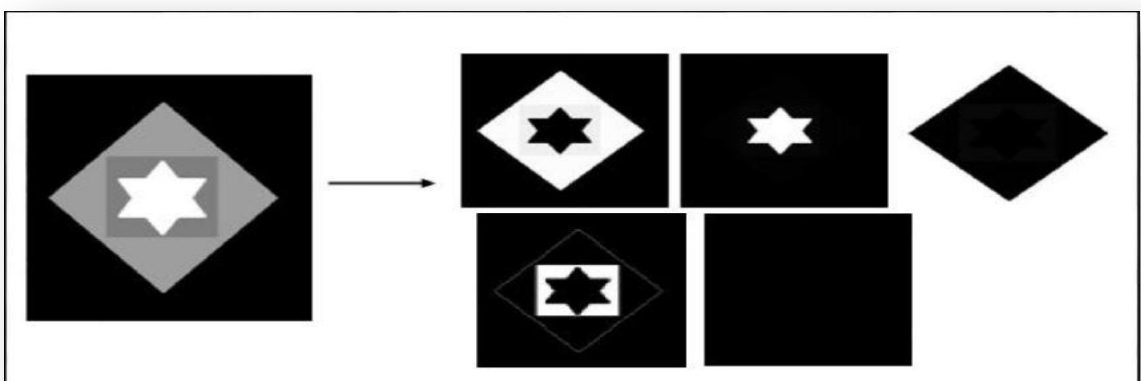


Figure II.9: Image segmenté avec FCM, pour $K=5$.

- ❖ FCM-S1 :
 - Pour $K=3$:




Figure II.10: Image segmenté avec FCM-S1, pour $K=3$.

- Pour $K=4$:




Figure II.11: Image segmenté avec FCM-S1, pour $K=4$.

- Pour $k=5$:

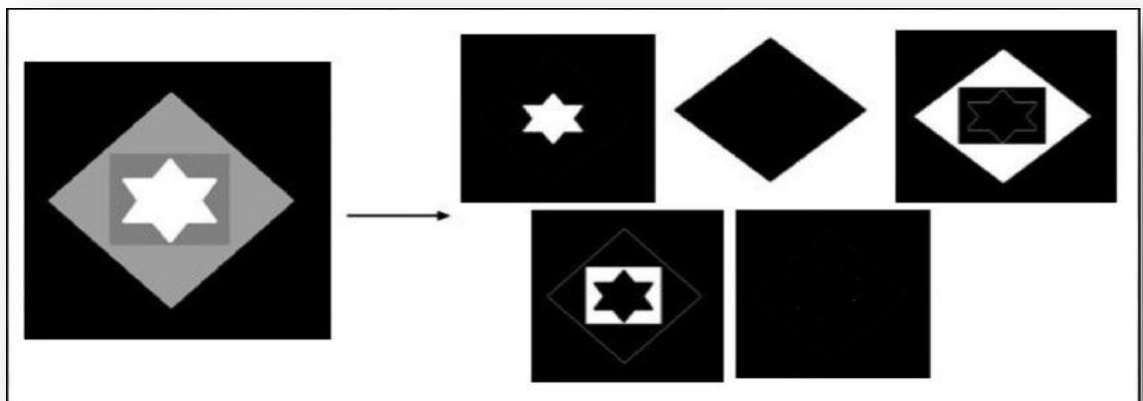


Figure II.12: Image segmenté avec FCM-S1, pour $K=5$.

- ❖ FCM-S2 :
 - Pour $K=3$:




Figure II.13: Image segmenté avec FCM-S2, pour $K=3$.

- Pour $K=4$:

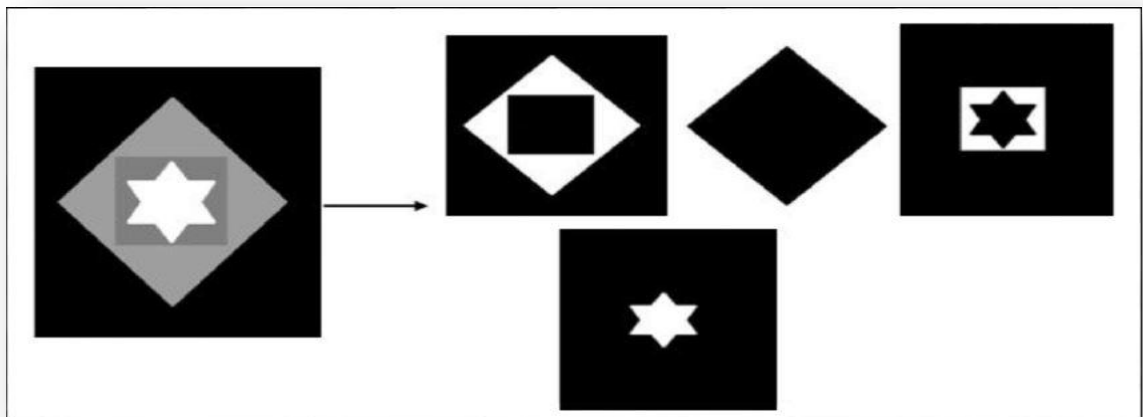


Figure II.14: Image segmenté avec FCM-S2, pour $K=4$.

- Pour $K=5$:




Figure II.15: Image segmenté avec FCM-S2, pour $K=5$.

➤ **Commentaire :**

Après avoir varié le nombre de classe K on a constaté que a chaque fois que on a pris le nombre K trop grand, ça nous a conduis à un partitionnement trop fragmenté des données ce qui empêche de découvrir des patterns intéressants dans les données, de la même manière, a chaque fois qu'on a pris le nombre de classe K trop petit, on remarque une classe manquante après segmentation de notre image.

II.6.2. Immunité au bruit :

Pour tester l'immunité des algorithmes décrits précédemment au bruit, nous avons ajouté à l'image synthétique 1 de la **Figure II.3** un bruit blanc Gaussien de moyenne nulle et de variance relative à la valeur moyenne de l'image voir **Figure II.16**, puis nous avons ajouté un bruit impulsionnel (Salt and Pepper) voir **Figure II.18**.

❖ **Bruit gaussien :**

Obtenu en ajoutant à chaque pixel une valeur aléatoire distribuée identiquement et indépendamment suivant une loi gaussienne de moyenne nulle et de variance σ .




Figure II.16 : image synthétique bruité avec bruit gaussien.

- **Résultats de segmentation pour K-Means, FCM, FCM-S1, FCM-S2 avec bruit gaussien:**

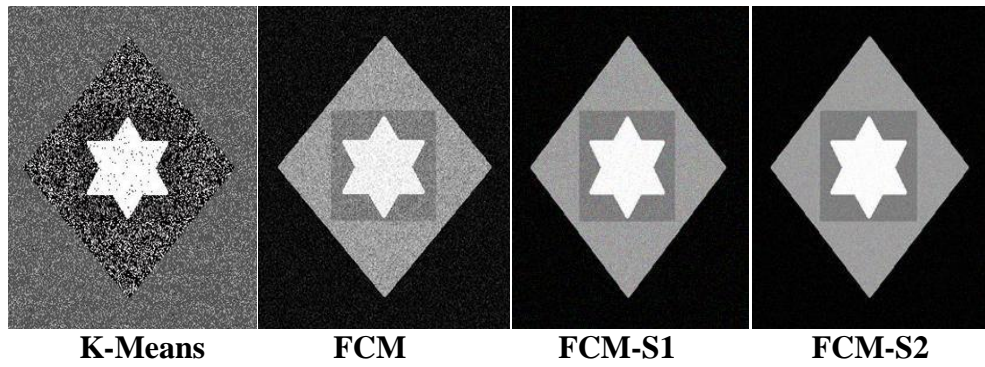


Figure II.17 : Résultats de la segmentation avec un bruit gaussien.

❖ **Bruit salt & pepper :**

Le bruit impulsionnel (Salt and Pepper) permet de modéliser le cas où certains pixels sont saturés ou morts.




Figure.II.18 : image synthétique bruitée avec salt & pepper.

- **Résultats de segmentation pour K-Means, FCM, FCM-S1, FCM-S2 avec bruit salt & pepper:**




Figure II.19 : Résultats de la segmentation avec un bruit Salt and Pepper.

➤ **Commentaire :**

Nous pouvons remarquer par rapport aux résultats observé sur les deux figures (II.17) et (II.19) que l'algorithme de K-Means et FCM sont sensible au bruit car ces deux derniers souffrent du manque de prise en compte de certaines informations en présence des artefacts. Les deux variantes du FCM (FCM-S1 et FCM-S2) résistent mieux aux inhomogénéités d'intensité comparée à l'algorithme du FCM, car ils prennent compte de l'influence du voisinage, et agissent comme un filtre moyennneur (pour FCM_S1) et médian (pour FCM_S2) sur l'image.

II.7. Conclusion :

La segmentation par classification permet de regrouper des objets en classes. Dans ce chapitre, nous avons présenté un panorama succinct des notions fondamentales du domaine de la segmentation des images ; on a exposé un état de l'art des différentes techniques existantes, classées selon leurs approches. Il n'y a pas de règles générales permettant de choisir une méthode particulière de segmentation pour un problème donné; choisir l'une ou l'autre dépend des images. Dans notre cas nous allons utiliser les méthodes de classification K-Means, FCM et ses variantes pour la segmentation d'une image synthétique en étudiant l'effet du bruit sur la segmentation et le choix de nombre de classes.

Chapitre III

III.1. Introduction :

L'étude du cerveau humain, que ce soit sur le plan anatomique ou fonctionnel, est actuellement un domaine de recherche en plein essor. Les principaux facteurs qui contribuent à rendre possibles ces études sont principalement l'évolution des matériels et des techniques d'imagerie. Une des techniques d'imagerie les plus couramment utilisées, à laquelle nous nous sommes intéressées dans le cadre de ce travail, est l'Imagerie par Résonance Magnétique (IRM) qui constitue une des avancées les plus significatives en médecine.

D'abord nous décrivons le cadre biomédical de notre travail. Nous commencerons par retracer l'anatomie cérébrale dont nous baserons sur les tissus du cerveau afin de comprendre les différentes substances de ce dernier que nous souhaitons segmenter en différentes classes, puis nous présenterons le principe de l'imagerie par résonance magnétique et les différentes coupes obtenues par cette dernière.

III.2. Anatomie cérébrale :

Le système nerveux central est constitué de l'ensemble des centres nerveux chargés d'assurer le fonctionnement des différents appareils de l'organisme. Il est relié à ces appareils par des nerfs. Il comprend (la moelle épinière, le tronc cérébrale, le cerveau, le cervelet). L'ensemble flotte dans un coussin protecteur de liquide céphalo-rachidien (LCR) [20].

III.2.1. L'encéphale :

Situé dans la cavité crânienne, l'encéphale est isolé dans des parois osseuses par les méninges. Il comprend quatre parties, le cerveau, le diencephale, le tronc cérébral [21].

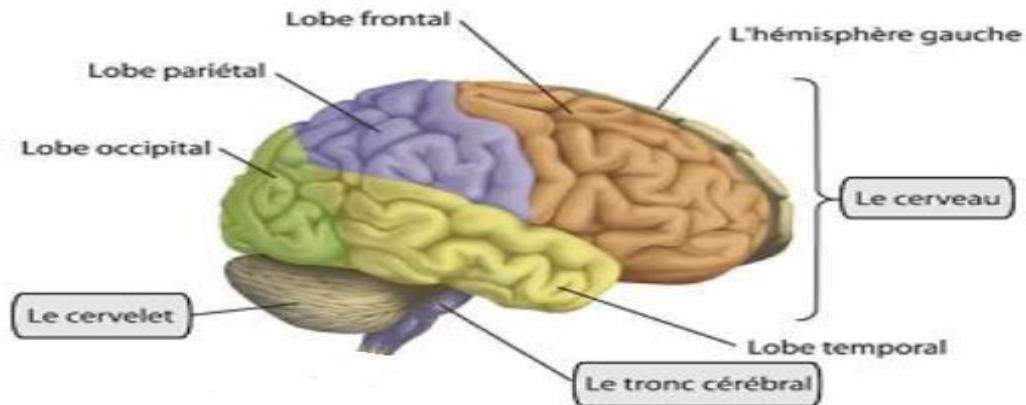


Figure III.1 : L'encéphale [4].

III.2.2. Le cerveau :

Le cerveau humain est un organe impair de forme schématiquement ovoïde à grand axe antéropostérieur, dont le volume moyen est de 1100 cm^3 chez la femme et de 1400 cm^3 chez l'homme. Le poids du cerveau varie de 1400 à 1800 gramme. Il occupe la boîte crânienne, mais il n'est pas en contact directe avec la cavité osseuse. Il baigne dans le liquide cérébro-spinal à l'intérieur d'une enceinte liquidienne [22].

Le cerveau est composé des hémisphères cérébraux, du cervelet et du **tronc cérébral**. Les hémisphères cérébraux sont constitués d'une portion profonde, la **substance grise**, qui comporte les corps cellulaires, d'une portion superficielle. La **substance blanche**, qui comporte les axones des cellules, et des ventricules, contenant le liquide cébrospinal [23].

Trois sillons plus accentués (scissure de Sylvius, sillon de Rolando, sillon perpendiculaire), divisent chaque hémisphère en quatre lobes (frontal, temporal, pariétal, occipital) comprenant chacun un certain nombre de circonvolutions [24] :

- Le lobe frontal.
- Le lobe pariétal, séparé du lobe frontal par le sillon central.
- Le lobe occipital, séparé du lobe pariétal par la fissure pariéto-occipital.
- Le lobe temporal, séparé du lobe frontal par la vallée sylvienne.

Le cerveau commande la plupart des fonctions du corps : la respiration, la contraction des muscles, les battements du cœur et les informations sensorielles : la vision, l'ouïe, toucher, l'odorat et le goût. Il est constitué de cellules nerveuse, les neurones, et de cellules qui en assurent le soutien, la protection et la nutrition, les cellules gliales. La

Chapitre III : Application à l'imagerie IRM

multiplication des cellules gliales, et non de celle des neurones résultent les principaux cancers du cerveau [25].

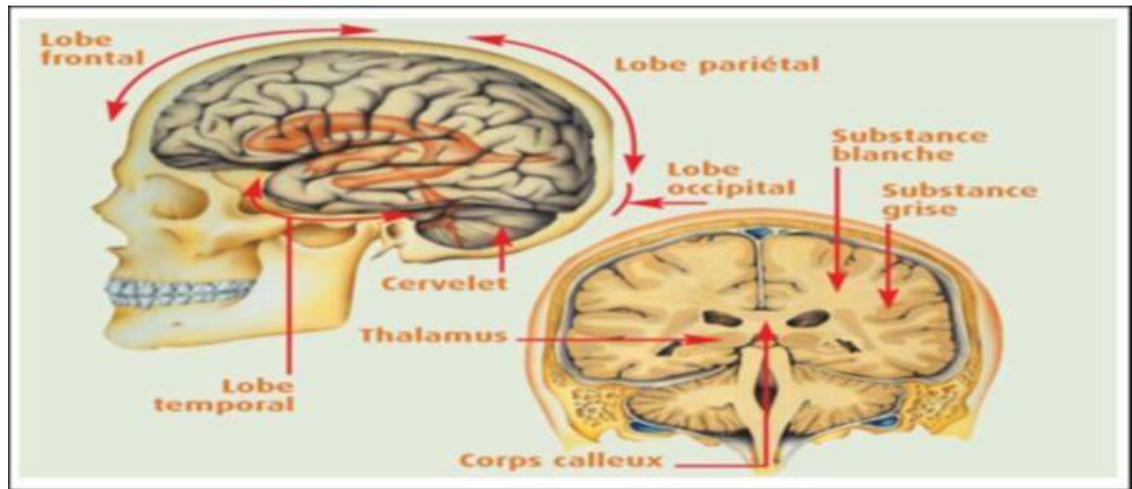


Figure III.2 : Structure générale d'un cerveau humain [5].

III.2.3. Cervelet :

Le cervelet est situé au-dessous du cerveau et en arrière du tronc encéphalique, auquel il est uni par les pédoncules cérébelleux. Il est divisé en deux hémisphères cérébelleux, droite et gauche, réunis par une structure médiane, le vermis. Il est divisé en trois lobes et sa surface est parcourue par des fissures. Sa face antérieure délimite avec le tronc cérébral le quatrième ventricule. Il est constitué de deux parties :

- Le cortex, couche périphérique de substance grise.
- Une partie centrale formée de substance blanche, le corps médullaire cérébelleux, et d'amas de substance grise disséminés, les noyaux du cervelet [26].

III.2.4. Tronc cérébrale :

Il fait suite à la moelle et se continue en haut avec les hémisphères cérébraux. Il communique en arrière avec le cervelet Il comprend de bas en haut [20]:

- le bulbe rachidien.
- la protubérance annulaire ou pont de Varole.
- les pédoncules cérébraux, recouverts en arrière par les tubercules quadrijumeaux.

III.3. Les Tissus du cerveau :

Le cerveau est constitué d'une substance blanche et d'une substance grise appelée cortex et du liquide céphalo-rachidien (LCR). Egalement, il contient des méninges pour sa protection.

III.3.1. Le liquide céphalo-rachidien :

Le cerveau baigne totalement dans un liquide biologique appelé liquide céphalo-rachidien (LCR) ou liquide cérébrospinal (en anglais cerebro-spinal fluid). Le « LCR » circule à travers des cavités appelées ventricules qui communiquent entre elles et joue un rôle très important en amortissant les chocs et les mouvements du cerveau. Il transporte les hormones, les nutriments, neurotransmetteurs et anticorps aux différentes parties du cerveau.

Le « LCR » est produit en permanence par les plexus choroïdes. Il circule en permanence et est résorbé par voie veineuse au niveau du secteur périphérique ou il se renouvèle trois à quatre fois par jour pour éliminer les déchets toxiques [27].




Figure III.3 : Circulation du liquide céphalo-rachidien.

III.3.2. La matière grise :

Les principales structures de substance grise (MG) sont le cortex, à la périphérie du cerveau, et les noyaux gris centraux. La substance grise est essentiellement composée de neurones et elle constitue le siège de l'activité cérébrale [28]. On la trouve par exemple dans le centre de la moelle épinière et dans le cortex (écorce des hémisphères cérébraux). Elle est responsable du traitement des informations.

III.3.3. La matière blanche :

La matière blanche (ou substance blanche) correspond à la gaine de myéline qui recouvre les axones des neurones pour en accélérer la conduction. Les axones myélinisés s'assemblent en faisceaux pour établir des connexions entre groupes de neurones [29].




Figure III.4 : Coupe de cerveau avec les trois matières principales [6].

III.3.4. Les méninges :

L'encéphale est entouré de couches protectrices appelées méninges. Elles sont constituées de trois membranes successives :

- La plus interne de ces membranes est la pie-mère : fine, compacte, elle contient les structures veineuses qui ramènent le sang, du cerveau vers le cœur.
- La membrane intermédiaire est l'arachnoïde, ainsi appelée en raison de sa ressemblance avec une toile d'araignée (le LCR circule entre celle-ci et la pie-mère).
- La membrane la plus externe est la dure-mère : dure et résistante, elle est formée de tissu conjonctif qui protège les couches sous-jacentes des os [30].

III.3.5. Les tumeurs cérébrales :

Une tumeur au cerveau est une masse intracrânienne due à une croissance incontrôlée des cellules on la trouve généralement dans les neurones, les tissus lymphatiques, les cellules gliales etc. [31]. Les Tumeurs cérébrales peuvent être primitives ou des métastases.




Figure III.5 : Présence d'une tumeur.

III.3.6. Les tumeurs cérébrales bénignes :

Elles 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 [32].

III.3.7. Les tumeurs cérébrales malignes

Elles sont Classées « cancéreuses », définissent certaines tumeurs primaires ainsi que toutes les lésions cérébrales métastatiques. Elles sont constituées de cellules qui se divisent relativement vite. Ces tumeurs croissent donc rapidement et peuvent envahir et endommager les structures cérébrales importantes. Elles peuvent être traitées par la chirurgie, la radiothérapie, la chimiothérapie ou la combinaison de celles-ci [32].

Chapitre III : Application à l'imagerie IRM

III.4. Imagerie par Résonance Magnétique (IRM)

L'IRM est une technique de diagnostic médicale permettant d'obtenir une vue 2D, 3D, voire 4D (3D+t) d'une partie du corps, notamment du cerveau et on coupe de grande précision anatomique. Cette technique est basée sur le phénomène physique de la résonance magnétique nucléaire (RMN). Il s'agit simplement d'observer la résonance magnétique nucléaire (RMN) des protons de l'eau contenus dans l'organisme. 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. La résonance magnétique nucléaire est une technique en développement depuis une soixantaine d'années dont le phénomène physique a été conceptualisé en 1946 par Bloch et Purcell [33].




Figure III.6 : Salle d'imagerie par résonance magnétique.

III.5. Observation du cerveau :

Le cerveau peut être observé par des coupes bidimensionnelles selon plusieurs angles de vue. Il existe principalement trois axes anatomiques qui permettent de réaliser les coupes : axiale, sagittale et frontale [34].

- Coupe axiale (ou transverse) : cette coupe représente une vue de dessus du cerveau. Elle correspond à un plan perpendiculaire au champ magnétique statique.
- Coupe sagittale : cette coupe est relative à un plan parallèle au plan inter-hémisphérique. Il s'agit de vues latérales du cerveau.
- Coupe frontale (ou coronale) : cette coupe est une vue de face du cerveau. Elle est acquise sur le plan perpendiculaire aux coupes axiale et sagittale.




Figure III.7 : Les trois axes de coupe pour la visualisation du cerveau.




Figure III.8 : Coupes IRM du cerveau : plan axial, coronal et sagittal (de gauche à droite).

III.6. Etude et résultats :

✓ Résultats

Nous avons fixé :

- Des images cérébrales en coupes axiale et coronale d'une personne adulte.
- Nombre de classe $K = 4$ (MB, MG, LCR et l'arrière-plan).
- Le degré de flou $m = 2$.
- Le critère d'arrêt $\varepsilon = 0.001$.
- Pour le FSM_S2, le coefficient de pondération $\alpha = 3$ et une fenêtre de 3X3.

III.6.1. Etude sans Bruit :

Dans ce qui suit nous allons procéder à une extraction des différentes classes de l'image (Matière Blanche **MB**, Matière Grise **MG**, le Liquide Céphalo-rachidien **LCR**) avec les différents algorithmes d'écrit auparavant:




Figure III.9: Image cérébrale de coupe 96.

Chapitre III : Application à l'imagerie IRM

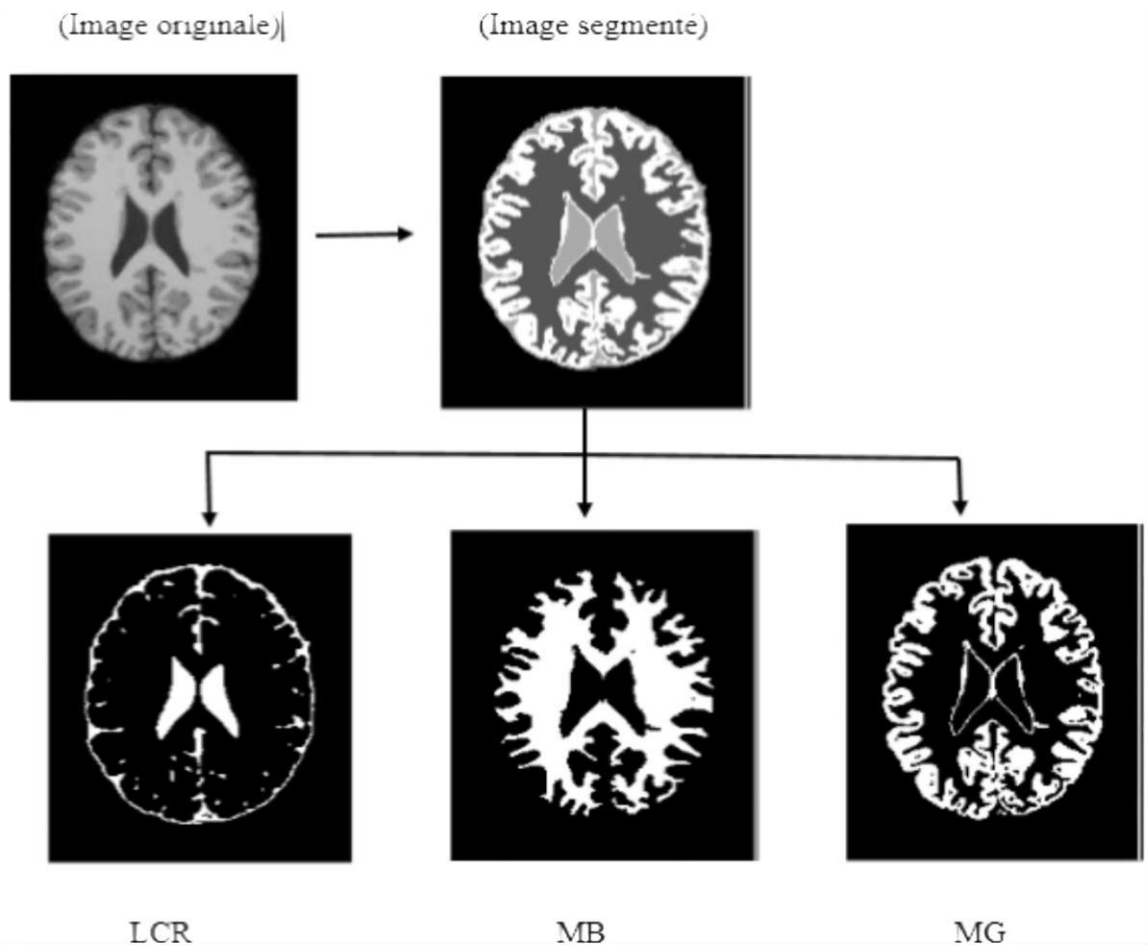


Figure III.10: Résultat de la segmentation par les K-Means.



Figure III.11: Résultat de la segmentation par les FCM.




Figure III.12: Résultats de la segmentation par les FCM-S1.




Figure III.13: Résultats de la segmentation par les FCM-S2.

Chapitre III : Application à l'imagerie IRM

III.6.2. Segmentation d'une image IRM en présence d'un bruit :

Pour tester la sensibilité et la robustesse des différents algorithmes vis-à-vis du bruit, nous avons ajouté à une image médicale de coupe 96 (figure III.9) composée de 4 classes (Matière Blanche **MB**, Matière Grise **MG**, le Liquide Céphalo-rachidien **LCR** et l'arrière-plan) un bruit gaussien ainsi qu'un autre bruit de type Salt & Pepper.

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





Figure III.14: Résultat de la segmentation par les K-Means d'une image avec un bruit Gaussien.




Figure III.15: Résultat de la segmentation par le FCM d'une image avec un bruit Gaussien.




Figure III.16: Résultat de la segmentation par le FCM-S1 d'une image avec un bruit Gaussien.




Figure III.17: Résultat de la segmentation par le FCM-S2 d'une image avec un bruit Gaussien.

❖ Bruit Salt&Pepper de variance $\sigma=0.02$:




Figure III.18: Résultat de la segmentation par les K-Means d'une image bruitée avec Salt & Pepper.




Figure III.19: Résultat de la segmentation par les FCM d'une image bruitée avec Salt & Pepper




Figure III.20 : Résultat de la segmentation par les FCM-S1 d'une image bruitée avec Salt &Pepper.




Figure III.21: Résultat de la segmentation par les FCM-S2 d'une image bruitée avec Salt &Pepper.

Chapitre III : Application à l'imagerie IRM

III.7. Critère d'évaluation :

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 :

$$Jaccard = \frac{A \cap B}{A \cup B} \quad (3.1)$$

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

$$Dice = \frac{2|A \cap B|}{|A| + |B|} \quad (3.2)$$

$D(A;B)$ 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 Gaussien			Image avec bruit Salt & Pepper		
	MG	MB	LCR	MG	MB	LCR	MG	MB	LCR
FCM	0.8763	0.9561	0.8801	0.6584	0.8103	0.6395	0.8199	0.9245	0.8000
FCM-S1	0.8550	0.9496	0.8643	0.7748	0.9068	0.7814	0.8009	0.8080	0.7604
FCM-S2	0.8740	0.9552	0.8753	0.7447	0.8817	0.7630	0.8462	0.9404	0.8555

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

Chapitre III : Application à l'imagerie IRM

	Image sans bruit			Image avec bruit Gaussien			Image avec bruit Salt & Pepper		
	MG	MB	LCR	MG	MB	LCR	MG	MB	LCR
FCM	0.9356	0.9778	0.9391	0.7979	0.8968	0.7878	0.9031	0.9613	0.8928
FCM-S1	0.9234	0.9745	0.9302	0.8757	0.9621	0.8812	0.8916	0.9527	0.8753
FCM-S2	0.9343	0.9774	0.9363	0.8563	0.9384	0.8703	0.9182	0.9697	0.9253

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

➤ **Commentaire :**

D'après les résultats des deux tableaux on remarque que dans le cas sans bruits, le FCM donne des résultats qui surpassent les autres algorithmes. En passant aux cas avec bruits on remarque que FCM-S1 est meilleur en présence d'un bruit gaussien. Pour les résultats trouvés avec l'algorithme du FCM-S2 on a constaté qu'en présence d'un bruit salt & pepper il surpasse les autres algorithmes, et qu'il donne des meilleurs résultats par rapport au FCM-S1 en absence du bruit.

III.8. Processus de classification de la tumeur

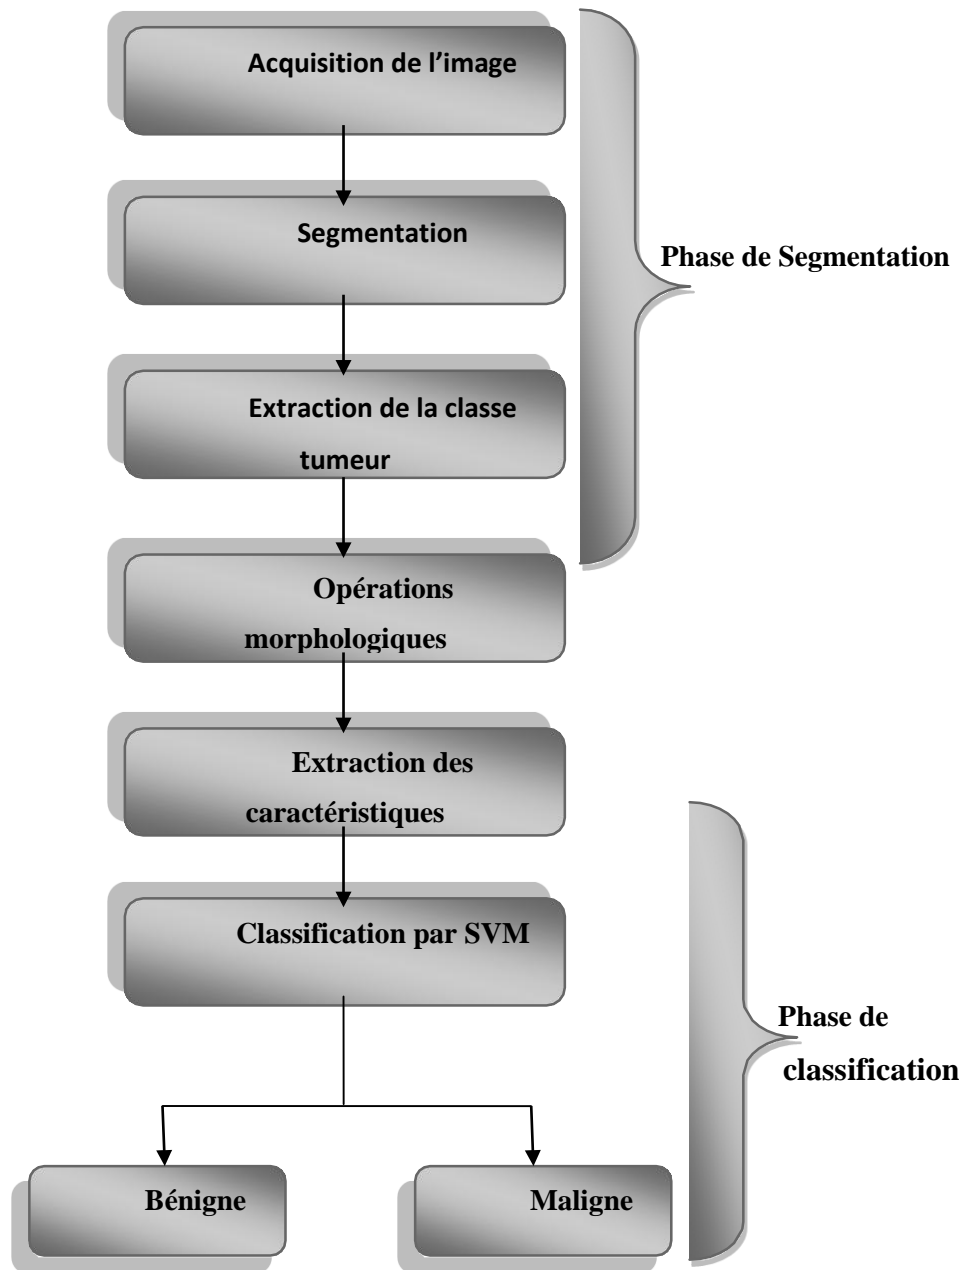


Figure III.22 : Processus de classification.

Chapitre III : Application à l'imagerie IRM

III.8.1. Opérations morphologique :

Le traitement d'image morphologique est un ensemble d'opérations non linéaires liées à la forme ou à la morphologie des caractéristiques d'une image. Une opération morphologique sur une image binaire crée une nouvelle image binaire dans laquelle le pixel a une valeur non nulle. Les opérations morphologiques transforment l'image [35].

a. Erosion :

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

$$(A) = A \ominus B \quad (3.3)$$

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:

$$\delta_B = A \oplus B \quad (3.4)$$

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.

Nous appliquons l'algorithme FCM-S2 en première phase afin de segmenter une image IRM ayant une tumeur au niveau du cerveau et nous procédons à l'extraction de ca la classe tumeur.




Figure III.23 : Extraction de la classe tumeur d'une image segmentée avec FCMS2.

En sélectionnant la classe représentant la tumeur et en appliquant les opérations morphologiques, nous aurons le résultat suivant (figure III.23).




Figure III.24: Résultat de l'opération morphologique sur la tumeur.

III.8.2.Extraction des caractéristiques : [36]

L'extraction de caractéristiques fait référence à la production d'informations pertinentes à partir d'images qui aident à résoudre d'autres tâches de calcul liées à certaines applications. Ainsi, l'extraction de caractéristiques peut être définie plus en détail comme suit:

1. Le résultat général de l'opération de voisinage calculé à partir d'une image
2. Propriétés structurelles ou texturales spécifiques de l'image qui peuvent aider à prédire les résultats

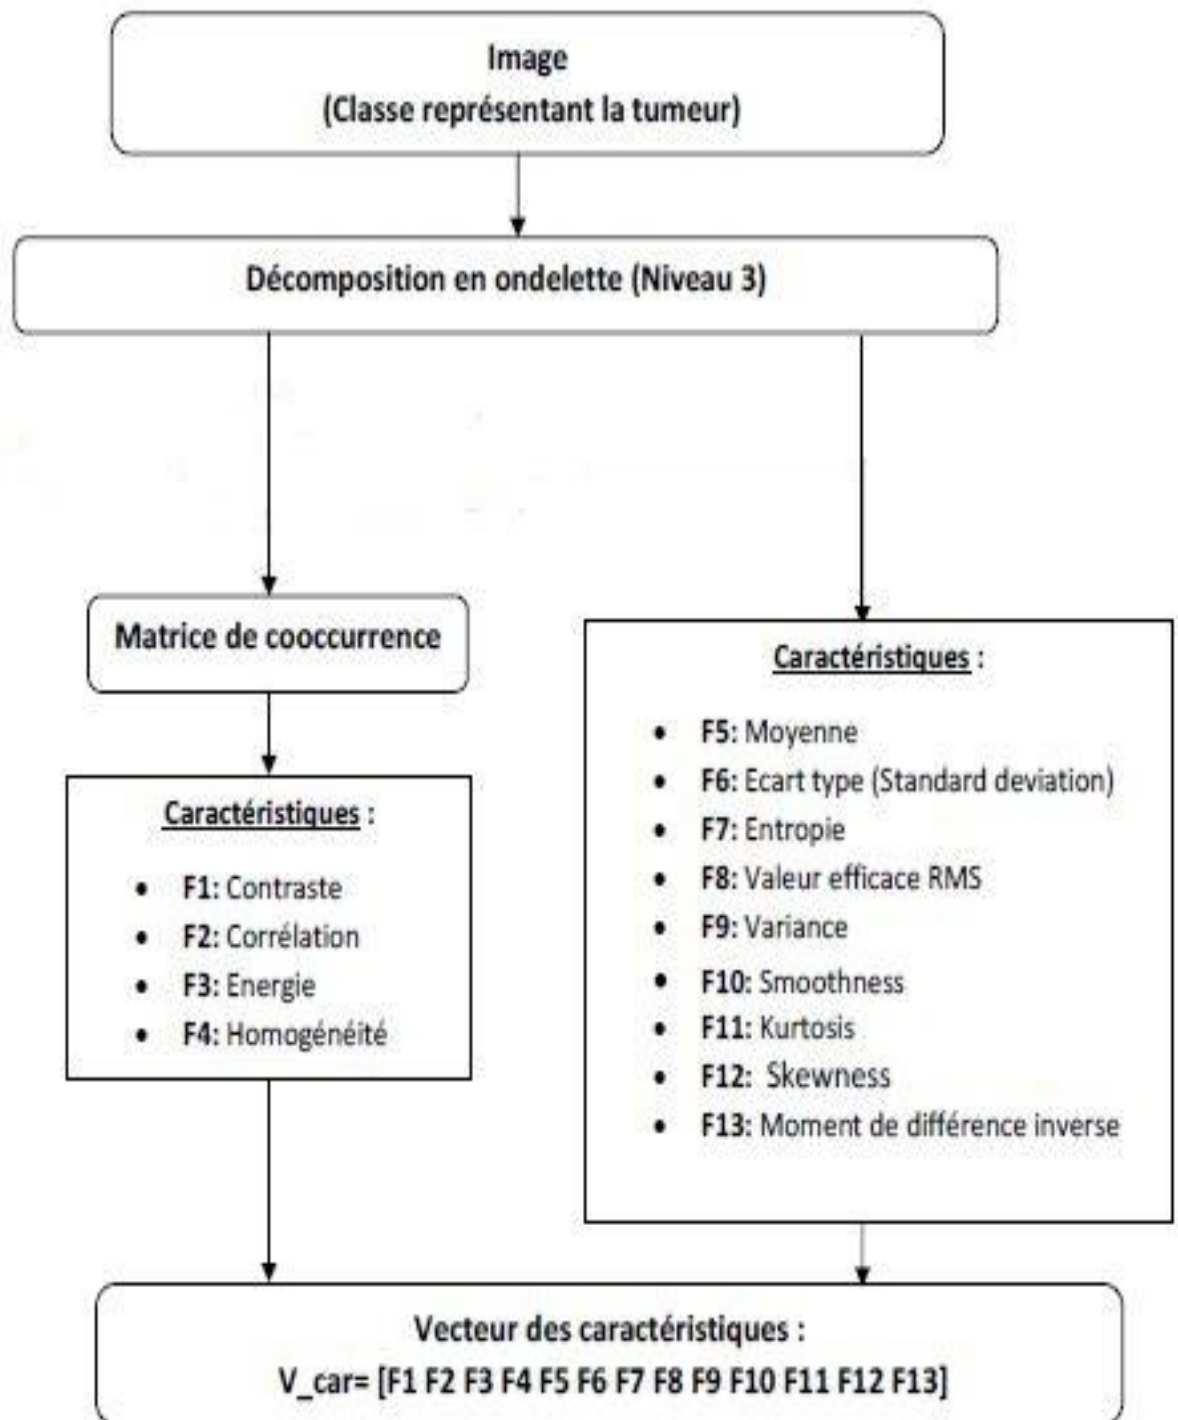


Figure III.25: Processus d'extraction des caractéristiques de la tumeur.

III.8.2.1. Transformée en ondelettes discrète :

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.

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 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 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.26.

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 [36].

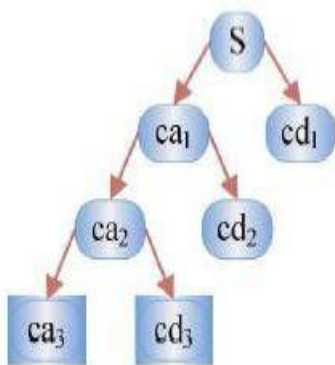


Figure III.26: Arbre de décomposition

niveau 3

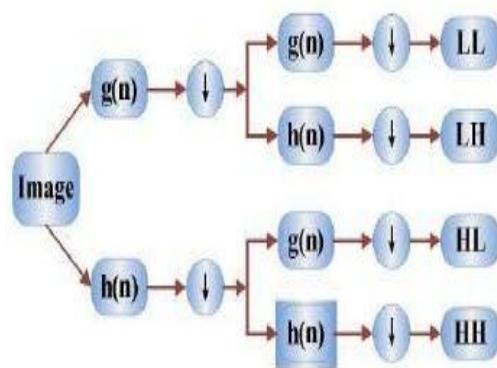


Figure III.27: Transformée en ondelettes

discrète s'applique à une image.

III.8.2.2. Matrice de cooccurrence :

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 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 d d'un pixel de niveau de gris i .

Certaines des caractéristiques texturales d'une image peuvent être extraites en utilisant la matrice de la matrice de cooccurrence (GLCM). Nous ne présentons ici que quatre de ces indices [36]:

a) F1: Contraste

La différence de valeurs d'intensité entre un pixel et son voisin sur toute l'image est appelée contraste. Le contraste est calculé à l'aide de l'équation suivante:

$$\sum_{i,j} |i - j|^2 p(i, j) \quad (3.5)$$

b) F2: Corrélacion

La corrélation définit la façon dont deux valeurs de pixels dépendent l'une de l'autre sur une considération linéaire de l'image entière. Elle varie de -1 à 1.

$$\sum_{i,j} \frac{(i - \mu_i)(j - \mu_j)p(i, j)}{\sigma_i \sigma_j} \quad (3.6)$$

c) F3: Energie

L'énergie est également connue sous le nom d'uniformité de l'image qui est la somme des éléments au carré de la matrice GLCM. La gamme d'énergie varie de 0 à 1.

$$\sum_{i,j} p(i, j)^2 \quad (3.7)$$

d) F4: Homogénéité

L'uniformité des éléments de distribution du GLCM à ses diagonales, qui varie de 0 à 1, est appelée homogénéité de l'image.

$$\sum_{i,j} \frac{p(i, j)}{1 + (i - j)^2} \quad (3.8)$$

Chapitre III : Application à l'imagerie IRM

• Dans ce qui suit, nous allons présenter les autres caractéristiques (F5 à F13) que nous utiliserons durant le processus de classification de la tumeur :

e) F5: La moyenne

Les valeurs d'intensité moyennes des pixels sont indiquées par cette caractéristique. N: dimension de l'image.

$$\frac{1}{N} \sum_{i,j} p(i,j) \quad (3.9)$$

f) F6: Ecart type (Standard deviation)

Il indique la variabilité des niveaux de gris, c'est-à-dire, le changement du contraste. m : valeur moyenne de $p(i,j)$.

$$\sqrt{\sum_{i=0}^{I-1} (i - m)^2 p(i,j)} \quad (3.10)$$

g) F7: Entropie

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.

$$-\sum_{i,j} (i,j) \log(i,j) \quad (3.11)$$

h) F8: Valeur efficace (RMS)

Le RMS fournit la moyenne arithmétique des carrés des valeurs moyennes (le long de chaque ligne ou colonne).

$$\sqrt{\frac{1}{N} \sum_{i,j} p(i,j)^2} \quad (3.12)$$

i) F9: Variance

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

$$\sum_{i,j} (1 + i - m)^3 * p(i,j) \quad (3.13)$$

Chapitre III : Application à l'imagerie IRM

j) F10: Smoothness

La mesure du contraste du niveau de gris est décrite comme la douceur relative.

$$1 - \frac{1}{1 + \sum_{i=0}^{l-1} (i - m)^2 p(i, j)} \quad (3.14)$$

k) F11: Kurtosis

Le pic ou la planéité d'une distribution de probabilité par rapport à la distribution normale fournit la mesure du kurtosis d'une image.

$$\sum_{i=0}^{l-1} (i - m)^4 p(i, j) \quad (3.15)$$

l) F12 : Coefficient d'asymétrie (Skewness)

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.

$$\sum_{i=0}^{l-1} (i - m)^3 p(i, j) \quad (3.16)$$

m) F13 : Moment de différence inverse (IDM)

IDM représente la texture de l'image. Sa valeur varie de 0 à 1, où 0,0 représente une image hautement texturée et 1,0 représente des images non texturées.

$$\sum_{i,j} \frac{p(i, j)}{1 + (i + j)^2} \quad (3.17)$$

- Après avoir réalisé l'extraction des caractéristiques on construit le vecteur caractéristiques V-car.

$$\mathbf{V_car} = [\mathbf{F1}, \mathbf{F2}, \mathbf{F3}, \mathbf{F4}, \mathbf{F5}, \mathbf{F6}, \mathbf{F7}, \mathbf{F8}, \mathbf{F9}, \mathbf{F10}, \mathbf{F11}, \mathbf{F12}, \mathbf{F13}].$$

III.9. Classification par SVM (Support Vector Machines) :

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 données 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.

Chapitre III : Application à l'imagerie IRM

La figure III.28 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 [37].

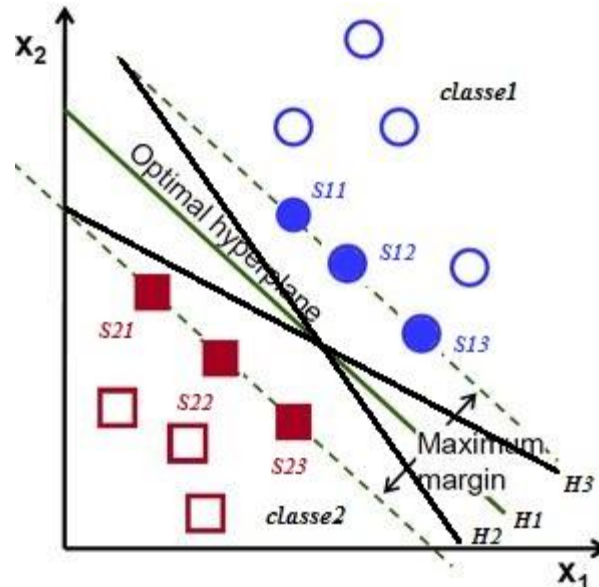


Figure III.28: L'interpolation géométrique des SVM linéaires

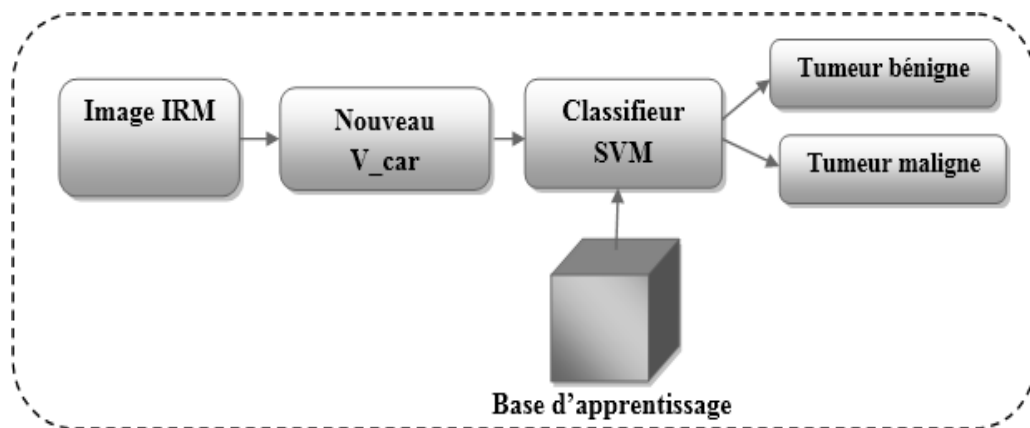


Figure III.29: Phase de classification de la tumeur par les SVM.

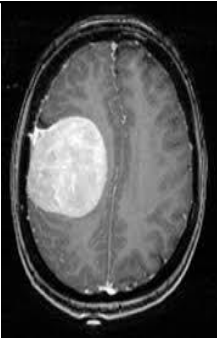
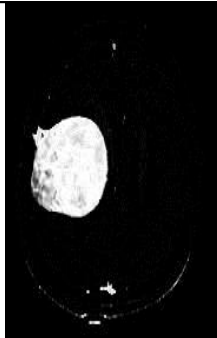
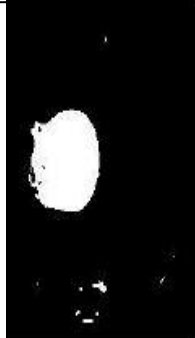
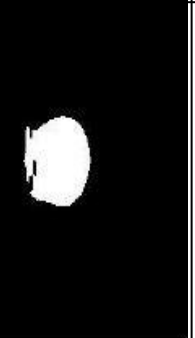

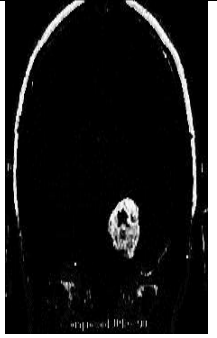
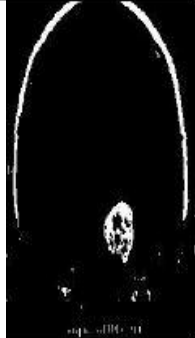

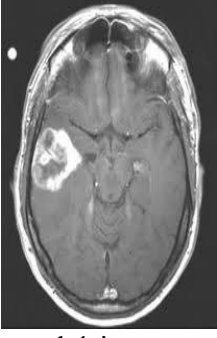



Chapitre III : Application à l'imagerie IRM

III.10. Résultats et discussion :

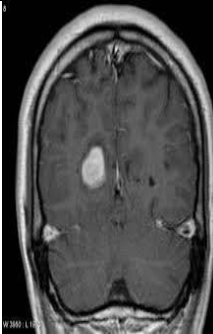

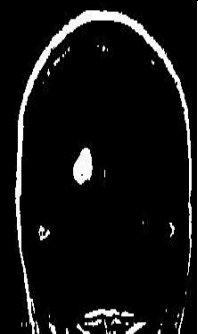

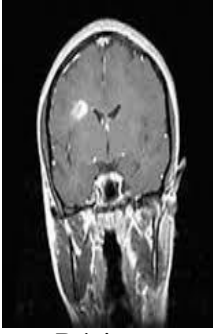

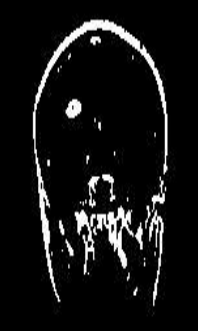

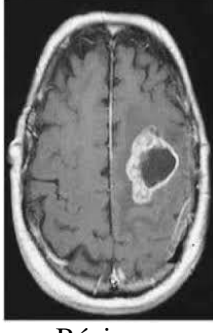
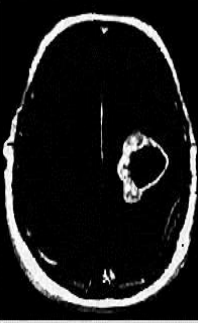


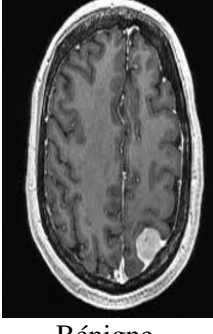

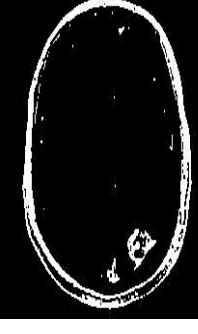





Dans ce qui suit, nous avons appliqué toutes les étapes précédentes sur 20 images (10 bénignes et 10 malignes) afin de classifier la tumeur obtenue en segmentant l'image IRM originale par le FCM-S2.

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

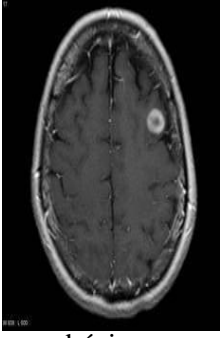
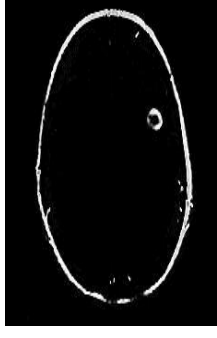
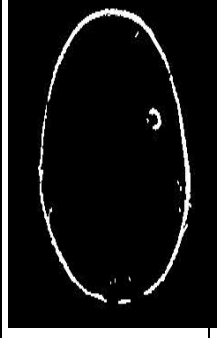
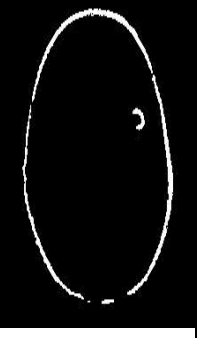
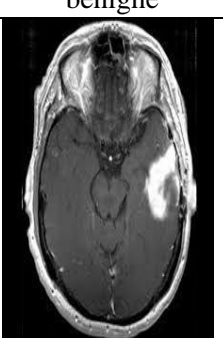



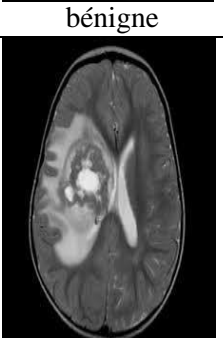
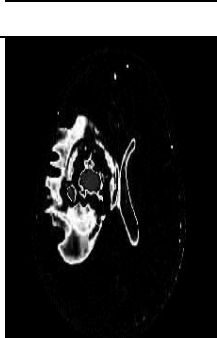




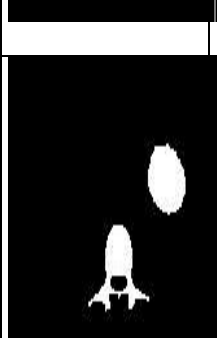
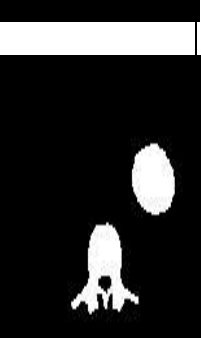
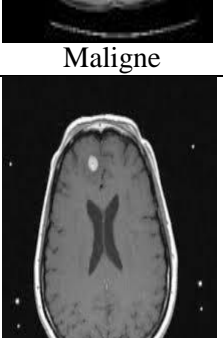

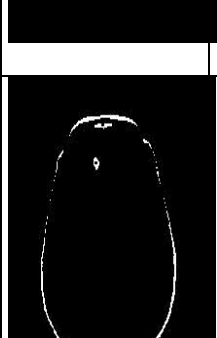

Le tableau suivant montre les résultats obtenus :

Image originale (Type de Tumeur)	Classe tumeur extraite avec FCM-S2	Tumeur extraite avant opérations morphologique	Tumeur extraite après opérations morphologique	Résultats avec le classifieur SVM
 bénigne				Bénigne
 bénigne				Bénigne
 bénigne				Bénigne

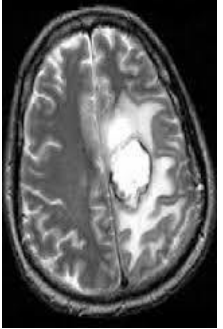
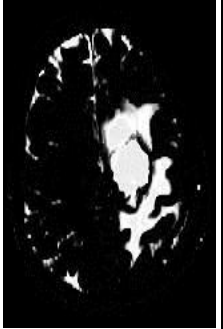


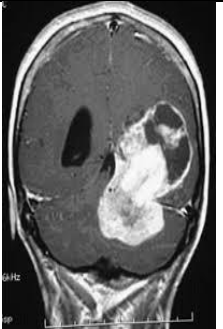



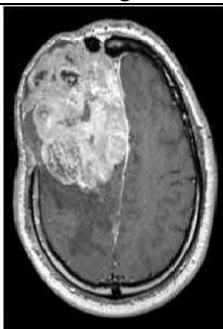
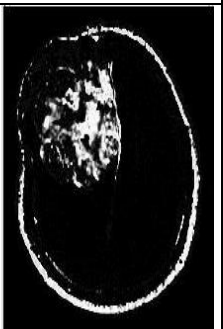


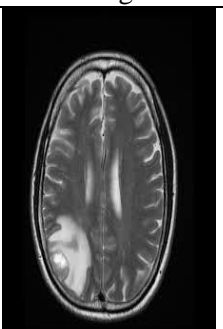



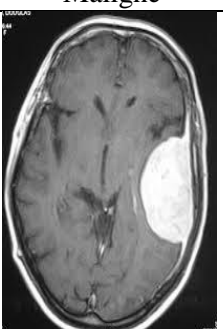

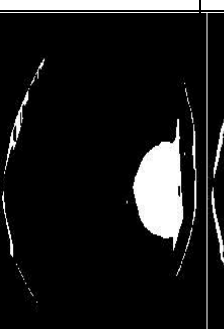

Chapitre III : Application à l'imagerie IRM

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

Chapitre III : Application à l'imagerie IRM

 <p style="text-align: center;">bénigne</p>				Bénigne
 <p style="text-align: center;">bénigne</p>				
 <p style="text-align: center;">Maligne</p>				Maligne
 <p style="text-align: center;">Maligne</p>				
 <p style="text-align: center;">Maligne</p>				Bénigne

Chapitre III : Application à l'imagerie IRM

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



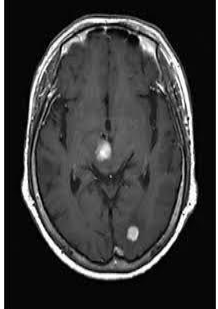
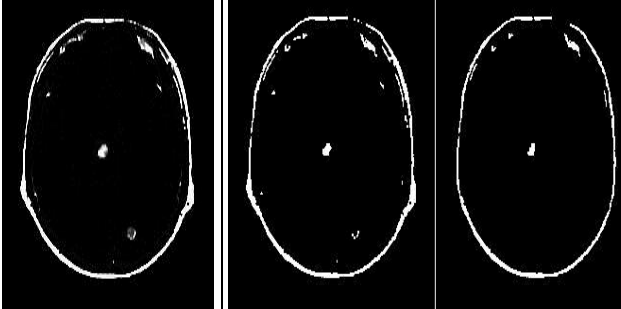
 Maligne		Maligne
 Maligne		Maligne

Tableau III.3: Résultats de la classification des tumeurs.

↪ Discussion des résultats :

Nous constatons que l'algorithme du FCM-S2 a bien détecté et segmenté la partie tumorale des images médicale utilisé et en combinant cette opération de segmentation avec des operateurs morphologiques (l'érosion dans notre cas) nous avons eu des images bien claires, ce qui nous a facilité la classification de ces parties tumorales.

D'après les résultats obtenue après classification on peut constater que 90% des tumeurs bénignes on était bien classée, et pour les tumeurs malignes on a eu 8 sur 10 images utilisée qui on était bien classé ce qui nous fait un taux de 80%.

Le tableau ci-dessous illustre les résultats obtenus sur l'ensemble de base de donnée utiliser qui contient 20 images au totale :

Classification	Correcte/10	Taux de classification(%)
Tumeur bénigne	9	90%
Tumeur maligne	8	80%

Tableau III.4: Taux de classification.

Chapitre III : Application à l'imagerie IRM

III.11. Conclusion :

Dans la première partie ce chapitre nous avons étudié quelques variantes du FCM qu'on a appliquée sur des images IRM.

Les résultats de segmentation obtenus sur des images IRM en absence et en présence du bruit, démontrent clairement la robustesse du FCM-S2, surtout en présence de bruit.

Dans la deuxième partie le système proposé dans ce chapitre suit une approche dans laquelle nous avons d'abord appliqué une segmentation en se basant sur le FCM-S2 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

Conclusion générale

De nos jours l'étude d'image IRM ne cesse d'évolué, les médecins cherchent toujours des résultats plus précis et mieux segmentés pour détecter la moindre anomalie qui présente une maladie chez les patients. Ce qui fait de la segmentation d'image IRM cérébrale est aujourd'hui très importante aux yeux des médecins, car elle leur offre une visibilité plus nette pour un bon diagnostic des maladies au niveau du cerveau humain. Cela est clairement bénéfique aux médecins et aussi à nous.

Le travail présenté dans ce mémoire concerne le domaine de traitement d'image et plus précisément celui de la segmentation d'image médicale obtenu par l'imagerie par résonance magnétique (IRM) qui reste un domaine de recherche très vaste et une étape cruciale dans tout processus d'analyse d'images. Elle consiste à préparer l'image afin de la rendre plus exploitable par un processus automatique tel que l'interprétation ou un diagnostic.

Comme nous avons pu le constater à travers cette étude, l'application des différentes méthodes de segmentation par classification de pixels ont abouti à des résultats de segmentation différents. Dans notre étude quatre algorithmes ont été testés pour répondre à des besoins spécifiques qui aboutissent à des classifications plus distinctes. Néanmoins comme nous avons pu le voir, la plupart de ces techniques nécessitent le choix des valeurs de certains paramètres dont les résultats peuvent dépendre très fortement et le fait qu'aucune connaissance a priori des données n'est disponible, impose l'utilisation de ces techniques. À cet effet, nous nous sommes intéressés aux méthodes dites non supervisées.

L'inefficacité pratique de la méthode des K-Means sur des images IRM, en vue d'une segmentation des tissus du cerveau en 3 classes à savoir (matière blanche, matière grise et le liquide-céphalo-rachidien), aboutit à des résultats moins performants par rapport aux autres méthodes. Ces dernières, utilisent la logique floue et introduisent la notion d'appartenance, arrivent à surpasser le problème lié à l'appartenance des pixels à une classe (un pixel peut appartenir à plusieurs classes avec différents degrés).

L'algorithme des FCM reste sensible au bruit et les propriétés spatiales des pixels ne sont pas prises en compte, pour cela la famille d'algorithme FCM-S dont nous avons choisi l'algorithme des FCM-S2 qui intègre l'information spatiale de l'image était très bénéfique, ce qui conduit à une classification plus adéquate et plus adaptée à l'identification des classes de l'image.

Conclusion générale

Pour notre travail dont l'objectif est la classification d'une tumeur au niveau du cerveau, nous avons utilisé l'algorithme FCM-S2 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. 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. Enfin, nombreuses images sont segmentées, cette méthode peut être appliquée pour segmenter d'autres structures cérébrales. Cette démarche peut être utilisée pour segmenter d'autres types d'images (images abdomen, images rétinienne, etc.).

Enfin, nombreuses images sont segmentées, cette méthode peut être appliquée pour segmenter d'autres structures cérébrales. Cette démarche peut être utilisée pour segmenter d'autres types d'images (images abdomen, images rétinienne, etc.).

Nous pouvant utiliser des paramètres de texture pour améliorer nos résultats. Et nous souhaitons aussi évoluer dans ce domaine de traitement d'images tel que la segmentation des volumes 3D et, éventuellement, le 4D, et faire une segmentation permettant d'extraire le volume d'intérêt et des images acquises des réseaux souterrains, plaques tectoniques et des recherches de matière première.

La prise en compte d'autres problèmes et contraintes comme la métrique utilisée (Distance euclidienne), l'initialisation des centres de classes (utilisation des metaheuristiques) ou encore la topologie de l'image, sont des paramètres importants qui peuvent améliorer la qualité de la segmentation. En plus de la stratégie de plusieurs algorithmes de segmentation travaillant en coopération permet de pallier aux problèmes rencontrés par l'utilisation d'un seul algorithme reste envisageable dans les futurs travaux.

Bibliographie

Bibliographie

- [1] : M.Bergounioux. « Introduction au traitement mathématique des images – méthodes déterministes ». Berlin, Heidelberg: Springer, 2015.
- [2] : S.Allart, A.Canivet. « Manuel d'analyse d'image avec logiciel ImageJ ». Institut national de la santé et de la recherche médical, 2017.
- [3] : Nguyen Tuan Thanh Le. [daidungsi's blog](https://daidungsi.wordpress.com/)-Science,Technology,English,Francais,..., [en ligne]. (Modifié le 28 juin 2010) Disponible sur: <https://daidungsi.wordpress.com/>).
- [4] : J.P.Cocquerez, S.Philipp. « Analyse d'images : Filtrage et segmentation ». Paris : Masson, 1995.
- [5] : M.Naoui. « Segmentation d'image par modèles statistiques de forme et d'apparence : problématiques et contributions ». Thèse de doctorat, Université d'Oran 1 Ahmed Ben Bella, 2015.
- [6] : N.Aissou, A.Benkaci. « Méthode coopérative pour la segmentation d'image : Application a l'imagerie médicale ». Mémoire Master, Université Abderrahmane Mira-Bejaia, 2016.
- [7] : S. Saleh, N. V. Kalyankar and S. Khamitkar. «Image segmentation by using edge detection». (IJCSE) International Journal on Computer Science and Engineering Vol. 02, No. 03, pp.804-807, 2010.
- [8] : M. R. Khokher, A. Ghafoor and A. M. Siddiqui. «Image segmentation using multilevel graph cuts and graph development using fuzzy rule-based system». IET image processing, 2012.
- [9] : D.Kaur, Y.Kaur. «Various Image Segmentation Techniques: A Review». (IJCSE) International Journal on Computer Science and Engineering Vol. 03, No. 05, pp.809 – 814, May 2014,.
- [10] : H. G. Kaganami and Z. Beij. «Region Based Detection versus Edge Detection». IEEE Transactions on Intelligent information hiding and multimedia signal processing, pp. 1217-1221, 2009.
- [11] : A. K. Jain, M.N. Murty, P.J. Flynn. « Data clustering: a review. ACM Computing Surveys». Vol. 31, N° 3, pp: 264-322, 1999.
- [12] : N.Azouza. «Segmentation par classification floue: application à l'imagerie par résonance magnétique». Mémoire Master, Université de Akli Moand Oulhadje-Bouira, 2018.

- [13] : M.Semchedine and L.Toumi. « Système Coopératif de Classification Floue Possibiliste avec Rejet d'Ambiguïté : Application à la segmentation d'images IRM ». 4th International Conference on Computer Integrated Manufacturing CIP, 2007.
- [14] : Barra.V. «Segmentation floue des tissus cérébraux en IRM 3D: une approche possibiliste versus autres méthodes ». Thèse doctorat. Université Blaise Pascal 1999.
- [15] : A.Mekhmoukh. « Segmentation d'images par classifieurs non supervisés : Application à L'Imagerie par Résonance Magnétique IRM ».Mémoire de Magister, Université A.Mira De Béjaia, Mai 2008.
- [16] : A.Mekhmoukh. « Segmentation d'images IRM par améliorations de l'algorithme FCM ». Thèse doctorat, Université de A.mira-Béjaia le 30/01/2016.
- [17] : M. Mokhtar Bendib. « Détection de pathologies à partir d'IRM cérébrales ».Thèse de doctorat ,2014/2015.
- [18] :L.O.Hall, A.M.Bensaid, L.Clarke, R.P.Velthuizen, M.Silbiger, J.C.Bezdek. « A comparison of neural network and fuzzy clustering techniques in segmenting magnetic resonance images of the brain. » IEEE Trans. Neural Networks, 3 (1992), 672 - 681
- [19] : A.N.Benaichouche. « Conception de métaheuristiques d'optimisation pour la segmentation d'images. Application aux images IRM du cerveau et aux images de Tomographie par Émission de positons ». Thèse de doctorat université paris 12, 2012.
- [20] : G.Braillon « Le système nerveux central » Doin éditeurs-Paris ; Imprimerie Lois Jean ,1984.
- [21] :P.Kamina « Anatomie clinique Tome 5 » Maloine, Paris ,2009.
- [22] :N.W.Daesslé « Imagerie du tenseur de diffusion pour l'étude de pathologie cérébrales » thèse doctorat, Université de Rennes, 2009.
- [23] :R.L.Drake,W.vogl,A.W.M.Mitchell « Gray's Anatomie pour les étudiants » Paris ,Elsevier,masson-SAS, 2006.
- [24] :L.William « Etude de l'évaluation des tumeurs cérébrales en IRM » cahiers d'IRM, Masson ,1989.
- [25] : <http://arc-cancer.net>.
- [26] :A.Thinhinane ,B.Fatima « Segmentation d'image par classifieurs flous :application a l'imagerie par résonance magnétique (IRM) » Université A.Mira Béjaia, 2015.
- [27] : Outrequin « Les hiérarchies fonctionnelles du système nerveux central sont fondées sur la phylogénèse » Neuro-anatomie fonctionnelle, 2007.

- [28] :G.Laurence « Trois principes de coopération pour la segmentation en Imagerie de Résonance Magnétique Cérébrale » Thèse de doctorat, Université Joseph Fourier, Grenoble 1, France, 1999.
- [29] :Brain Web « Similated Brain Data base » Mc cconnel Brain Imagerie center ,Montreal neurological Institute, Mc Gill, 2015.
- [30] :S.Belarouci,S.Benmokhtar « Méthode coopérative pour la segmentation d'images IRM cérébrales basée sur les techniques FCM et Level Set » Mémoire de Master en génie Biomédical , Université Abou-Bakr Belkaid ,Telemcen, 2011/2012.
- [31] :A.Sophie capelle « Segmentation d'image IRM multi-échos tridimensionnelles pour la détection des tumeurs cérébrale par la théorie de l'évidence » thèse doctorat Université de poitiers , 2003.
- [32] : D.Slimane. « Segmentation d'image médicales basées sur une coopération FCM et Level Set ».mémoire Master 2, université Mouloud Maameri, Tizi-Ouzou , 2015.
- [33] : F.Bloch « Nuclear Induction , physical review » vol 70, American physical society california,1946.
- [34] :P.L.Boumghar « Déploiement sur une plateforme de visualisation,d'un algorithme xcoopératif pour la segmentation d'image IRM basé sur les systèmes multi-ages » mémoire Master 2, université des sciences et de la technologie Houari Boumedien 2011.
- [35] : O.Swe Zin; K.Aung Soe. "Bain tumor detection and segmentation using watershed segmentation and morphological operation". International Journal of Research in Engineering and Technology, 2014; vol.03, n°03, PP.367-374. Disponible sur: <http://www.ijret.org> (Consulté le 15/10/2020).
- [36] : Aswathy K Cherian; E.Poovammal; C. Malathy. "Automatic feature extraction for breast density segmentation and classification". Asian journal of pharmaceutical and clinical research, 2017, vol.10, Issue 12,PP. 111-115.
- [37] : Y. Zhang; L. Wu, "An mr brain images classifier via principal component analysis and kernel support vector machine",Progress In Electromagnetics Reseach,Vol. 130, 369-388, 2012.

Références figures

- [1] : N.Azouza. « Segmentation par classification floue: application à l'imagerie par résonance magnétique ». Mémoire Master, Université de Akli Moand Oulhadje-Bouira, 2018.
- [2] : N.Aissou, A.Benkaci. « Méthode coopérative pour la segmentation d'image : Application a l'imagerie médicale ». Mémoire Master, Université Abderrahmane Mira-Bejaia, 2016.
- [3] : N. Nasri, K. Mokrani. « Segmentation d'images par FCM modifié considérant le contexte spatiale ».Thèse de doctorat en électronique à l'université de Ouargla, 2013.
- [4] :A.Thinhinane ,B.Fatima « Segmentation d'image par classifieurs flous :application a l'imagerie par résonance magnétique (IRM) » Université A.Mira Béjaia, 2015.
- [5] :D.A.Massinisa ,B.Sofine « Segmentation d'image IRM cérébrale par FCM et ses variantes » Université Mouloud Mammeri, Tizi-Ouzou,2013.
- [6] :Source, www.esil.univ-mrs.fr.

Résumé

La segmentation d'image est une opération de traitement d'image de bas niveau qui consiste à localiser dans une image les régions (ensembles de pixels) appartenant à une même structure. Les méthodes qui lui sont liées sont variées et peuvent s'appuyer sur diverses bases théoriques (Probabilités, logique floue) et se répartissent en trois grandes familles (contour, région et classification).

Nous nous intéresserons essentiellement à la segmentation par approche classification qui fournit une partition de l'image en regroupant des pixels ayant des niveaux de gris similaires dans une même classe de pixels. L'objectif de ce mémoire est d'étudier différentes méthodes de classification non supervisées (K-means, FCM et FCM-S) et de les confronter afin de les appliquer sur des images cérébrales IRM en vue d'une segmentation et d'une classification des différentes régions correspondantes aux différentes tissus et structures et de mettre en oeuvre des techniques de segmentation permettant la détection des tumeurs cérébrales et les classer maligne ou bénigne.

Mots clés: Image IRM, la classification de la tumeur, la tumeur bénigne et maligne, Segmentation d'image, FCM, FCM-S.

Abstract

Image segmentation is a low-level image processing operation which consists in locating in an image the regions (sets of pixels) belonging to the same structure. The methods which are linked to it are varied and can be based on various theoretical bases (Probabilities, fuzzy logic) and are divided into three large families (contour, region and classification).

We are mainly interested in segmentation by classification approach which provides a partition of the image by grouping pixels with similar gray levels in the same class of pixels. The objective of this dissertation is to study different methods of unsupervised classification (K means, FCM and FCM-S) and to compare them in order to apply them to MRI brain images with a view to segmentation and classification of different regions corresponding to different tissues and structures and to implement segmentation techniques allowing the detection of brain tumors and classify them as malignant or benign.

Keywords: MRI image, tumor classification, benign and malignant tumor, Image segmentation, FCM, FCM-S.