

République Algérienne Démocratique et Populaire

**Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université Mouloud MAMMARI, Tizi-Ouzou**



Faculté de Génie Electrique et d'Informatique
Département d'Automatique

MEMOIRE DE FIN D'ETUDES

En vue de l'obtention du diplôme

*De MASTER ACADEMIQUE EN AUTOMATIQUE
OPTION : COMMANDE DES SYSTEMES*

Thème

Classification Par FCM

En analysant la texture et la forme

Application Aux Images Médicales

Proposé et dirigé par :
Melle Nait Belaid Ouiza

Présenté par : Bengana Amar

Soutenu le : 03/10 /2013

Promotion 2013

Remerciement

Mes vifs remerciements vont tout d'abord à Melle NAIT BLEAID OUIZA pour m'avoir proposé le thème de ce mémoire et m'avoir dirigée, aidée et conseillée tout le long de notre travail. et surtout pour sa patience un grand merci.

Nous exprimons notre reconnaissance pour les membres de jury pour avoir fait honneur en acceptant de jugé notre mémoire.

Je n'oublie pas non plus de remercier toutes les personnes que j'ai pu rencontrer et avec lesquelles j'ai pu échanger, et en particulier les enseignants du département d'Automatique.

Je remercie également l'ensemble du personnel du département d'Automatique de l'Université de Mouloud Mammeri Tizi-Ouzou.

Je remercie, enfin, toutes les personnes qui ont contribué de près ou de loin à la réalisation de ce travail.

Dédicaces

Je tiens à dédier ce travail :

- A celle qui est partie très tôt , j'ai aimé partager ses instants avec toi , que dieu te garde dans son vaste Paradies ;ma mère
- A toi mon père et a ta femme.
- A toi pour ton soutien inconditionné moral ou financier ma reconnaissance n'a pas de limite ; said
- A ta sagesse ta façon de m'encourager ta présence malgré tout un grand merci ; lynda
- A mes adorables petits frères ;hocine et yasmina
- A vous mes amis soufiane, bylka, laziz, taous, lilia, nassima.
- A toutes la famille Bengana et Abed ;
- A toute la promotion automatique 2012/2013 ;
- A tout ce qui ont contribué de près ou loin à la réalisation de ce travail.

Résumé

Le travail traité dans ce mémoire, s'inscrit dans le domaine médicale plus précisément l'aide au diagnostique.

Notre objectif est de classifiez l'es images IRM cérébrales en deux classes saines et

Pathologiques a l'aide d'un algorithme de classification le FCM, pour cela nous avons utilisé deux approches : l'analyse de la forme et de texture pour caractériser les image.

Pour la texture on a choisi de travaillé avec trois méthodes la matrice de cooccurrence, les filtre de Gabor et la décomposition en ondelettes, et on a utilisé les moments invariants de hu pour analysé la forme. a l'aide des programme implanté sous matlab on a eu des résultats qui nous a permet de choisir la meilleur approche qui nous donne de meilleur performance en taux de classification.

Mots clefs : classification, fcm, texture, forme, matrice de cooccurrence, filtre de Gabor, décomposition en ondelettes, les moments invariants de hu

Sommaire

Introduction générale.....	1
Chapitre I:	
I.1.Introduction.....	3
I.2.Les techniques d'acquisition d'images médicales.....	3
I.2.1.Les rayons X.....	3
I.2.1.1.Le scanner.....	3
I.2.1.2 La radiographie.....	4
I.2.2 Les ultrasons	5
I.2.2.1. L'échographie.....	5
I.2.2.2. Le Doppler.....	6
I.2.3.l'imagerie médicales nucléaire	7
I.2.3.2.la scientographie.....	7
I.2.3.2.la tomographie par émission de positons.....	8
I.2.4. Les fibres optiques	8
I.2.5. L'imagerie par résonance magnétique :	10
I.2.5.1.Utilisation d'IRM dans le diagnostic des tumeurs cérébrales.....	12
I.3.1.Anatomie du cerveau	12
I.3.2.Observation du cerveau.....	13
I.3.3.Les séquences d'acquisition.....	14
I.4.Les maladies cérébrales	14
I.4.1.L'épilepsie	14
I.4.2.La maladie de Parkinson	14
I.4.3.La sclérose en plaques	15
I.4.4.Les accidents vasculaires cérébraux	16
I.4.5.La démence	16
I.5.Conclusion.....	17
Chapitre II :	
II.1.Introduction.....	18
II.2.Descripteurs visuel utilisés.....	18

II.2.1.Les descripteurs de textures	18
II.2.1.1Matrice de cooccurrence.....	18
II.2.1.2.Les filtres de Gabor	20
II.2.1.3.Les ondelettes	22
II.2.2.Les descripteurs de formes	23
II.3.Conclusion.....	25
Chapitre III:	
III.1.introduction.....	26
III.2.Définition de la classification.....	26
III.3.Méthodes de classification.....	27
III.3.1.Méthodes supervisées	27
III.3.1.1.K-plus proches voisins.....	27
III.3.1.2.Réseaux de neurone.....	28
III.3.1.3.Algorithme de Bayes.....	29
III.3.1.4.Algorithme des Machines à vecteurs supports.....	29
III.3.2.Méthodes Non Supervisées	30
III.3.2.1.La méthode des <i>k</i> -means.....	30
III.3.2.1.1.Présentation	30
III.3.2.1.2.algorithme.....	31
III.3.2.2.Méthodes hiérarchiques	31
III.3.2.3.Algorithme des C-moyennes floues.....	32
III.4.FCM.....	32
III.4.1.Définition.....	32
III.4.2.Représentation matricielle d'une partition floue d'un ensemble discret.....	33
III.4.3.Le principe.....	33
III.4.4.Algorithme.....	35
III.4.5.Convergence des c-moyennes floues (FCM)	36
III.4.6.Paramètres de FCM.....	36
Chapitre IV : tests et classification	
IV.1.Introduction.....	37
IV.2.La base d'images utilisé pour la classification	37
IV.3.Critères de performances.....	37
IV.4.Tests et résultats	38
IV.4.1.Résultats de classification avec les descripteurs de texture	38

IV.4.1.1.Matrice de cooccurrence.....	38
IV.4.1.2.Ondelettes	40
IV.4.1.3.Filtre de Gabor.....	41
IV.4.2.Résultats de classification avec les descripteurs de forme	42
IV.4.2.1.Moments de Hu.....	42
IV.4.2 Résultats avec la combinaison la texture et la forme.	43
IV.5. choix des paramètres de FCM.....	44
IV.5.1. nombre de classe « c »	44
IV.5.2. Influence de paramètre flou sur la classification.....	45
IV.6\$.Conclusion.....	46
Conclusion générale.....	47
Annexe.....	48
Référence Bibliographique	

Liste des figures et tableau

Chapitre I :

Fig.1. Scanner	4
Fig.2. Exemple d'image scanner	4
Fig.3. appareil radiographique.....	5
Fig.4. image radiographique.....	5
Fig.5. Un échographe.....	6
Fig.6. Exemple d'images doppler.....	7
Fig.7. gamma-caméra.....	8
Fig.8. Image scintigraphique.....	8
Fig.9. Appareil endoscopie.....	9
Fig.10. Exemple d'image endoscopique.....	9
Fig.11. L'IRM et la salle d'analyse des réalisations	11
Fig. 12. Schéma d'un cerveau humain. Vue sagittale à gauche. Vue coronale à droite.....	12
Fig.13. Les trois axes de coupe pour la visualisation du cerveau.	13
Fig.14. Coupe sagittale	13
Fig.15. Coupe axiale	13
Fig.16. Coupe frontale.....	13
Fig.17. image du cerveau atteint d'épilepsie.....	14
Fig.18. cerveau seins a gauche cerveau atteint d'un parkinson a droite.....	15
Fig.19. image du cerveau atteint d'une sclérose en plaque.....	15

Liste des figures et tableau

Fig.20.image illustre l'accident vasculaire cérébrale.....16

Fig.21.image du cerveau atteint de la démence.....17

Chapitre II :

Fig.1. ondelette de Haar22

Fig.2. ondelette Daubechies22

Chapitre III :

Fig.1. Principe de la classification27

Fig.2.structure d'un réseau de neurone multicouche.....29

Chapitre IV :

Fig.1. Exemple d'images de la base utilisée(a)images seines (b) images pathologiques.....37

Fig.2. Histogramme des performances obtenu avec la matrice de cooccurrence.....39

Fig.3. Histogramme qui représente les performances obtenu avec les ondelettes.....41

Fig.4. Histogramme qui représente les performances obtenu par les moments de hu.....43

Fig.5. Histogramme qui représente les performances obtenu par hu avec les ondelettes...44

Fig.6. Histogramme qui représente les performances obtenu avec les ondelettes.....45

Annexe:

Fig.1. Graphe d'une fonction triangulaire.....49

Fig.2. Graphe d'une fonction gaussienne.....49

Fig.3. Graphe d'une fonction trapézoïdale.....50

Fig.11.Schéma d'un système floue.50

Liste de tableau

Tableau O1. Quelques valeurs d'attributs de 04 images de la base.....38

Tableau O2.Résultats de la classification avec la matrice de cooccurrence39

Liste des figures et tableau

Tableau.3 les valeurs des indices de texture extrait avec les ondelettes.....	40
Tableau.4 Résultats de la classification avec les ondelettes.....	41
Tableau.5 les valeurs des attributs de texture extrait par le filtre de Gabor.....	41
Tableau.6 Résultats de la classification avec le filtre de gabor.....	41
Tableau.7. La valeur des moments invariants de Hu (ordre 3).....	42
Tableau.8. Résultats de la classification avec les moments invariants de hu.....	42
Tableau.9. Résultats de la classification avec la combinaison des ondelettes avec les moments invariants de hu.....	43

Introduction générale

Le traitement d'images est né de l'idée de la nécessité d'introduire des modèles mathématiques pour aider l'homme dans sa vie quotidienne. La vision intervient dans un grand nombre d'activités humaines, le champ des applications du traitement d'images est très vaste ; la médecine est un des domaines qui n'a pu échapper à ce souffle numérique que ce soit dans la chirurgie, le diagnostic, la pratique thérapeutique etc. Le but du traitement des images médicales est d'extraire à partir des images acquises, les informations utiles au diagnostic, de révéler des détails difficiles à percevoir à l'œil nu, tout en évitant la création d'artefacts. Pour cela le traitement fait appel à des outils, des algorithmes, qui permettent d'agir sur l'image numérisée ; L'un des processus dans la chaîne de traitement d'image est la classification.

Dans la littérature il y a plusieurs méthodes de classification leur but est d'identifier les classes auxquelles appartiennent des objets à partir de certains traits descriptifs. Elles conviennent en particulier au problème de la prise de décision automatisée. Les techniques de classifications sont de deux types, supervisées et non supervisées : les techniques supervisées dont on connaît a priori la nature des objets du terrain étudié, et non supervisées, où les regroupements d'objets sont faits selon une logique de proximité ou d'appartenance à des niveaux numériques voisins.

Notre travail consiste à représenter chaque image par un ensemble de caractéristiques visuelles de bas niveau telle que la texture et la forme. Ces caractéristiques visuelles, calculées de manière automatique, la classification c'est la phase au cours de laquelle sont utilisés ses attributs précédemment extraits afin d'atteindre l'objectif initial. le classifieur recevra en entrée les paramètres calculés.

L'objectif de ce travail est la classification des images IRM cérébrales saines et pathologiques. Le but recherché est de trouver une méthode de caractérisation des images dans le but de les classer après avec l'algorithme c moyenne flou.

Notre manuscrit comportera les parties suivantes :

Introduction générale

- ✓ Le premier chapitre, expose un aperçu sur l'imagerie médicales les différentes méthodes d'acquisition d'images médicale, on va se focalisé sur l'IRM cérébrale, on va aussi explorer le cerveau et les maladies qui l'atteint.
- ✓ Le second chapitre, décrit Les différentes méthodes utilisée dans notre mémoire pour analysé les images et extraire les attributs
- ✓ Le troisième chapitre, a pour but de décrire l'algorithme de c moyenne flou sa représentation, l'influence de ses paramètres et ses différentes variantes développé en vue d'améliorations.
- ✓ Le dernier chapitre est consacré aux différents tests et résultats
- ✓ A la fin nous terminons par une conclusion générale.

I.1.Introduction

De plus en plus, l'imagerie médicale est utilisée dans toutes les étapes de la pratique médicale, aussi bien lors du diagnostic ou de la planification de thérapie, qu'en contrôle de la thérapie. L'imagerie médicale regroupe un ensemble de méthodes permettant de visualiser des processus biologiques au sein même des organismes vivants sans procéder à une opération. Il existe aujourd'hui plusieurs méthodes d'imagerie médicale, dont les plus répandues sont Les rayons X , L'imagerie par résonance magnétique (IRM) , Tomographie par ordinateur (CT scan) et Médecine nucléaire.....


I.2.Les techniques d'acquisition d'images médicales

I.2.1.Les rayons X [1]

Le rayon X est un rayonnement électromagnétique composé de photons. Utilisé dans l'imagerie médicale, il fut découvert en 1895 par le physicien Wilhelm Röntgen. Les rayons X permettent au médecin de faire un diagnostic non seulement plus rapide, mais aussi plus sûr.

I.2.1.1.Le scanner

Le scanner X, appelé également scanner à rayons X, scanographe, scanneur ou tomodensitomètre est apparu à la fin des années soixante. Comme la radiographie classique, le scanner s'appuie sur l'absorption plus des rayons X selon le milieu traversé (les os, par exemple, étant beaucoup plus absorbants que les tissus mous). L'avantage de cette technique par rapport à la radiologie classique est l'obtention, grâce à sa sensibilité, de résultats, coupe par coupe, Le scanner X permet de visualiser tous les éléments profonds de l'organisme, Son principe est en effet de choisir un plan de coupe et d'effectuer de multiples projections sous différents angles afin de connaître le coefficient d'atténuation en chaque point du plan.

**Fig.1.** Scanner**Fig.2.**Exemple d'image scanner

Le scanner est un appareil très utilisé dans le milieu médical même si la radiologie reste l'appareil de premier examen. Il sert surtout pour diagnostiquer des tumeurs, lésions et fractures. Sa résolution temporelle est de l'ordre de quelques secondes ou millisecondes suivant la partie du corps à étudier et sa résolution spatiale est excellente puisqu'elle permet des coupes du corps humain de l'ordre du millimètre. Toutefois cette technique est purement anatomique et ne donne pas de renseignements sur les fonctions cérébrales, c'est pourquoi dans la recherche sur le cerveau on utilise maintenant l'IRM. Mais l'inconvénient majeur du scanner X est la grande dose de rayons X reçu par le patient; il faut tout de même savoir que les cellules nerveuses sont peu sensibles aux radiations.

I.2.1.2 La radiographie[2]

Une radiographie était simplement un film radiographique sur lequel on pouvait observer des contrastes qui correspondaient aux différentes structures internes de l'organisme radiographié. Différentes technologies comme l'informatique ou les produits de contrastes ont ensuite donné naissance à plusieurs types de radiographies. Pour des questions pratiques, les appareils utilisés diffèrent légèrement selon leur zone d'application (dentition, poumons, squelette...).

Le principe de la radiologie est une impression photographique par les rayons X sur un film argentique (plus précisément une cassette contenant un film sensible à la lumière visible et recouverte généralement de un ou deux écrans renforçateurs qui s'illuminent lorsqu'ils sont exposés aux rayons X). Les rayons X peuvent traverser la matière, ce qui explique que la

quantité de rayons X reçue dans les différentes zones du film dépend de l'absorption des rayons X par les différents tissus traversés soit leur densité.



Fig.3.appareil radiographique
pulmonaire



Fig.4.image radiographique

avant la radiographie, on effectue une injection (intraveineuse, rectale, orale ou intra articulaire) d'un produit de contraste "radio opaque", La radiographie obtenue sera alors plus contrastée, elle paraîtra plus nette, plus fine, et sera donc plus facilement interprétable. Le produit de contraste le plus souvent utilisé est l'iode.

I.2.2 Les ultrasons [3]

Les ultrasons sont utilisés dans l'imagerie médicale et principalement dans le domaine de l'échographie et du doppler. Nous avons choisi d'étudier plus particulièrement l'échographie.

I.2.2.1. L'échographie

L'échographie est une technique d'imagerie médicale récente puisqu'elle est apparue il y a vingt ans. Cette technique permet d'explorer toutes sortes d'organes (muscles, articulations, foie, rein, vessie et même le fœtus). L'examen dure 15 à 30 minutes et il permet d'établir un diagnostic rapide. L'appareil utilisé pour réaliser les échographies s'appelle un échographe (figure 5).

On place une sonde sur la région à examiner après avoir appliqué sur la peau un gel qui permet de supprimer la présence d'air entre la sonde et la peau (l'air empêche la transmission d'ultrasons)



Fig.5.Un échographe

Les images d'échographies sont le plus souvent monochromes. Quand vous y voyez des couleurs, c'est que l'on utilise le doppler et le codage couleur (pour plus d'infos, voir l'encadré concernant le doppler).

I.2.2.2. Le Doppler

En 1842, le physicien autrichien Christian Doppler a observé qu'il y avait une variation apparente de la fréquence d'une onde émise par une source en mouvement par rapport à un observateur immobile.

Grâce à l'application de cet « effet », il est possible, désormais, d'étudier un écoulement de la circulation du sang par exemple. En effet, lorsqu'une onde se réfléchit sur un objet en mouvement, comme un globule rouge, elle change de fréquence. L'analyse de ce changement permet de reconstituer les mouvements.

C'est grâce à ce système que certaines images d'échographie sont en couleur mais le langage de ces couleurs n'a aucun rapport avec la réalité : les flux qui se rapprochent sont en rouge (ou jaune), ceux qui s'éloignent en bleu et les turbulences en vert.




Fig.6.Exemple d'images doppler

I.2.3. L' imagerie médicale nucléaire [4]

L'imagerie médicale nucléaire consiste en l'administration d'un traceur radioactif (ou radiotracteur) au patient permettant sa détection externe Elle permet d'étudier le fonctionnement des organes. Les deux types d'examens (la scintigraphie et la TEP) de la médecine nucléaire consistent en l'administration dans l'organisme de très faibles doses dites « traceuses », d'un médicament radiopharmaceutique (composé d'un produit physiologique et d'un isotope radioactif).Des appareils d'imagerie appelés « caméras » détectent les rayonnements émis par l'isotope radioactif, ce qui permet la réalisation de clichés qui seront ensuite analysés.

I.2.3.1. La scintigraphie[5]

C'est un moyen qui permet de voir l'image d'un organe. Elle est utile pour voir le fonctionnement de cet organe, ou l'analyse d'un foyer réceptif anormal. Au cours de cet examen, on administre à la personne un radiopharmaceutique. Cet examen est appelé examen isotopique, examen scintigraphique ou scintigraphie.

Cet examen consiste à injecter au malade un produit radioactif (émetteur de rayons gamma) qui varie selon l'organe examiné. Le produit va se fixer de façon passagère sur certains tissus ou organes. Une fois fixé, on mesure la radioactivité sur l'organe ou les tissus grâce à un appareil appelé gamma-caméra : c'est une table équipée d'une ou plusieurs caméras spéciales qui captent le rayonnement gamma.



Fig.7. gamma-caméra




Fig.8. Image scintigraphique

Cet examen est utile pour les analyses métaboliques comme le système digestif ou le cerveau ou des structures inaccessibles en détail pour les rayons X et qui bloquent les ultrasons. Le prix d'un appareil est de 400 000 euros.

Les progrès effectués sur les gamma-caméras laissent présager de l'amélioration de la résolution.

I.2.3.2. la tomographie par émission de positons

Elle fournit aux équipes médicales des diagnostics précoces dans le cas d'une maladie. La tomographie par émission de positons fonctionne sur le même principe que la scintigraphie. Contrairement aux isotopes utilisés en scintigraphie, les radioéléments émetteurs de positrons sont des éléments chimiques légers et abondants dans la matière vivante .

I.2.4. Les fibres optiques

L'utilisation de fibre optique dans l'imagerie médicale est assez variée, que ce soit pour le diagnostic de certaines maladies ou encore pour le traitement de divers problèmes de santé. Par exemple, un simple câble de fibre optique est introduit dans le corps pour y transporter la lumière. Cette lumière sera par la suite réfléchi par les organes et captée par un autre câble de fibre optique qui transportera l'information vers un système de capture de signaux lumineux.

- **L'endoscopie**

L'endoscopie consiste à introduire un tube, l'endoscope, muni d'une optique et d'un système d'éclairage dans l'organisme. Cette technique est souvent utilisée pour rechercher la cause d'un trouble.

L'endoscopie diagnostique sert à explorer un organe, pour y déceler d'éventuelles anomalies, tumeurs, traces d'une pathologie.

L'endoscopie opératoire, quant à elle, permet de réaliser des gestes thérapeutiques, comme l'ablation d'une tumeur, sans avoir recours à la chirurgie traditionnelle.

L'équipement endoscopique est composé:

- ✓ D'un fibroscope
- ✓ Une source de lumière
- ✓ Un flacon de lavage
- ✓ Une pince à biopsie
- ✓ Une pince à corps étranger
- ✓ Un aspirateur

Les accessoires sont indispensables au bon fonctionnement et au succès de l'examen. Il convient dès lors de s'assurer que l'ensemble est adapté aux besoins, fonctionnel et complet, afin de réaliser l'examen. L'endoscopie nécessite l'utilisation d'un endoscope, qui est un outil révolutionnaire pour les chirurgiens. Il existe plusieurs sortes d'instruments.



Fig.9. Appareil endoscopie



Fig.10.Exemple d'image endoscopique

L'endoscopie est une technique d'imagerie médicale :

- facile à réaliser
- pouvant être répétée sans danger car elle ne comporte aucun risque d'irradiation
- très précise puisqu'elle offre des indications de texture du tissu, de volume ou de coloration alors que la radiographie n'offre essentiellement que des images linéaires en noir et blanc ;
- qui peut se réaliser avec un minimum d'ouverture corporelle, ce qui entraîne un rétablissement du patient dans de bien meilleures conditions et beaucoup plus rapidement ;
- permettant à la fois de regarder et d'agir in situ. En effet l'endoscopie a l'avantage considérable d'être un examen "en direct" de certains organes.

L'examen peut poser quelques problèmes. C'est souvent assez désagréable puisque l'on introduit l'endoscope dans l'organisme et l'examen nécessite une anesthésie.

I.2.5. L'imagerie par résonance magnétique :

L'imagerie par résonance magnétique (I.R.M.) dérive d'une application de la technique d'analyse chimique par résonance magnétique nucléaire (R.M.N.). L'IRM est la méthode de diagnostic la plus puissante et la plus sensible disponible actuellement. Cet outil permet d'obtenir des images de tissus à l'intérieur du corps humain plus précises que celles obtenues par un scanner ou par ultrasons.

Le patient est allongé sur un lit d'examen mobile qui doit ensuite être rentré dans le tunnel de l'aimant. L'IRM soumet le corps à un champ magnétique très puissant qui va orienter les atomes d'hydrogène (les protons : élément présent en abondance dans l'eau du corps humain) dans la même direction. Pour réaliser une image IRM, une antenne émet une onde de radio fréquence courte modifiant l'orientation des protons. A l'arrêt de l'émission, ils reviennent à leur position initiale. Ils restituent alors de l'énergie enregistrable sous forme de signal, capté par une antenne réceptrice. Puis en analysant grâce à un ordinateur les signaux de résonance fournis par ces mouvements, on peut obtenir une image tridimensionnelle des organes, présentée en coupes successives.

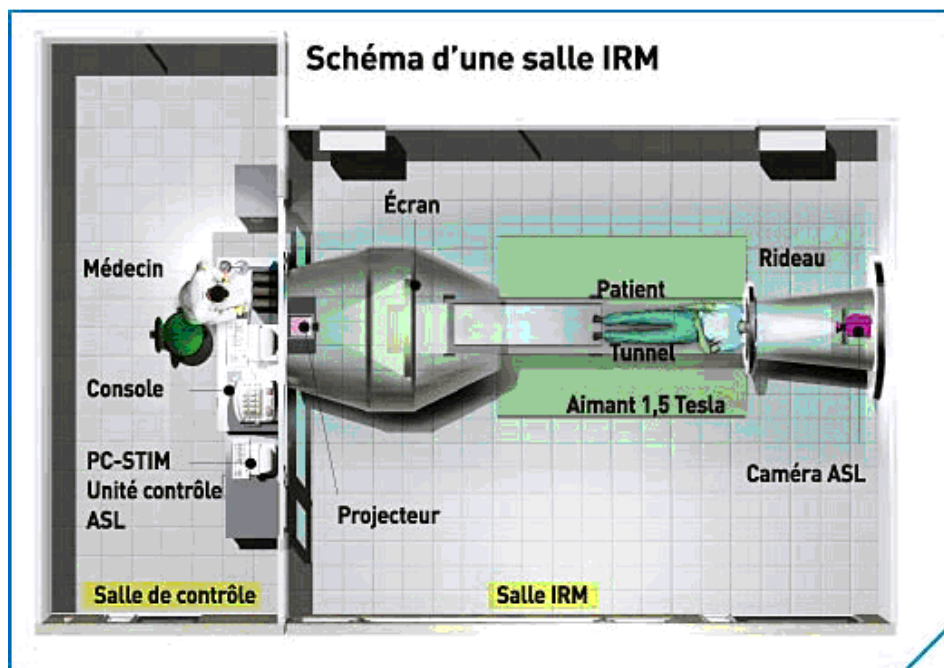


Fig.11. L'IRM et la salle d'analyse des réalisations

Il a une capacité à réaliser des coupes dans tous les plans de l'espace et permet une ébauche de caractérisation tissulaire (eau, graisse, sang, os,...). Cette technique n'utilise pas les rayons X mais les propriétés magnétiques du corps humain.

Cette technique permet de représenter avec une grande précision anatomique l'intérieur du corps dans toutes les directions et même en volume, sans la moindre conséquence pour le patient. Grâce aux contrastes, on décèle les plus petites tumeurs, les plus petits angiomes ou accidents vasculaires... L'un des avantages de l'IRM est l'absence d'injection de traceur extérieur. Par ailleurs, les rayonnements sont totalement inoffensifs.

L'examen est long, une heure environ, il est nécessaire de rester immobile d'où l'anesthésie général. Lors de l'examen, le patient est inconfortablement installé puisqu'il est maintenu à l'intérieur d'un tube étroit et bruyant dû aux impulsions électromagnétiques. En effet, le bruit est un inconvénient puisqu'il est en corrélation avec la qualité de l'image : l'augmentation du champ magnétique permet d'améliorer le contraste mais également l'intensité du bruit.

Cependant, il est contre indiqué en cas de claustrophobie et en cas de présence d'un corps étranger métallique dans le corps.

I.2.5.1. Utilisation d'IRM dans le diagnostic des tumeurs cérébrales

L'IRM est un examen très pratiqué pour diagnostiquer les tumeurs cérébrales. Il permet une plus grande localisation anatomique quand à l'endroit où se situe la tumeur, son retentissement, son extension. De plus, elle permet de savoir si la tumeur présente une composition liquidienne ou non, elle localise aussi les tumeurs faibles volumes, et aussi dans une zone impossible d'accès au scanner le tronc cérébral.

I.3.1. Anatomie du cerveau

Le cerveau c'est l'étage le plus élevé dans la hiérarchie fonctionnelle du système nerveux central. Il est spécialement développé chez l'homme. Son poids moyen est de 1400 à 1800 grammes. Le cerveau est placé dans la boîte crânienne où il repose sur la base du crâne et il est recouvert par la voûte. Le cerveau est la partie la plus volumineuse du système nerveux central. Il est constitué essentiellement de deux hémisphères, séparés par la scissure inter-hémisphérique, et reliés par différentes structures telles que le corps calleux, le thalamus et l'hypothalamus. Le cerveau est composé de substances (ou matières) : la matière blanche et la matière grise et baigne dans un liquide appelé liquide céphalo-rachidien (Fig.12.)




Fig. 12. Schéma d'un cerveau humain. Vue sagittale à gauche. Vue coronale à droite.

I.3.2.Observation du cerveau

Les coupes axiale, frontale et sagittale sont des coupes du cerveau approximativement parallèles, respectivement, au plan qui comprend nez et oreilles, au plan du visage et au plan de symétrie de la tête . Ces coupes sont orthogonales deux à deux (cf. Figure 1.2).



Fig.13. Les trois axes de coupe pour la visualisation du cerveau.

- 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.

Voici les images IRM qui illustre les différentes coupes du cerveau.




Fig.14.Coupe sagittale




Fig.15.Coupe axiale




Fig.16.Coupe frontale

I.3.3. Les séquences d'acquisition

Les paramètres de séquence sont les paramètres que le manipulateur fixe sur la console pour définir la séquence IRM. Ils permettent de contrôler l'influence des différents paramètres tissulaires T1, T2 et densité de proton dans le signal "pondération" et de moduler ainsi le contraste dans l'image.

I.4. Les maladies cérébrales

I.4.1. L'épilepsie

C'est une maladie en rapport avec une excitation involontaire et aléatoire de l'activité cérébrale. Elle entraîne des mouvements involontaires (tremblements, morsure de la langue, perte d'urines) et une altération de la conscience allant jusqu'à la perte de connaissance.




Fig.17. Image du cerveau atteint d'épilepsie

I.4.2. La maladie de Parkinson

Elle est liée à une dégénérescence d'une partie du cerveau nommée « locus Niger » qui a pour effet de priver les noyaux gris centraux de dopamine. Le contrôle du mouvement n'est plus assuré par les noyaux gris et c'est ce qui explique les principaux symptômes de cette maladie : troubles de la marche, de l'élocution, de la réalisation de tâches mécaniques et simples.




Fig.18.cerveau seins a gauche cerveau atteint d'un parkinson a droite

I.4.3.La sclérose en plaques

Elle est une maladie des gaines de myéline qui entourent et protègent les fibres nerveuses. C'est l'ensemble des processus nerveux qui peut alors être touché avec des troubles sensoriels (vision), des troubles moteurs (paralysie, troubles de la marche), des troubles de l'élocution...




Fig.19.image du cerveau atteint d'une sclérose en plaque

I.4.4. Les accidents vasculaires cérébraux

Ils sont liés soit à une interruption de l'apport de sang au cerveau (accident vasculaire cérébral ischémique), soit à une hémorragie (accident vasculaire cérébral hémorragique). Les AVC ischémiques peuvent être en rapport avec une obstruction des petits vaisseaux (intracérébraux) ou avec l'existence d'une thrombose (c'est-à-dire, d'une obstruction causée par un caillot), d'un tronc artériel plus important. Les cellules cérébrales ne sont alors plus approvisionnées en oxygène ou en éléments énergétiques, elles peuvent se détériorer, voire mourir. Les AVC hémorragiques, pour leur part, sont liés à un saignement à l'intérieur du cerveau.




Fig.20. image illustre l'accident vasculaire cérébrale

I.4.5. La démence

Peut être d'origine vasculaire et apparaître dans les suites d'accidents vasculaires peu importants mais répétés. Elle peut aussi être liée – et c'est le cas le plus fréquent – à une dégénérescence de certaines structures du cerveau. C'est le cas de la maladie d'Alzheimer liée au dépôt d'une protéine, la bêta-amyloïde, sur les structures nerveuses et à la présence de filaments enchevêtrés dans les cellules nerveuses.




Fig.21.image du cerveau atteint de la démence

I.5.Conclusion

Nous avons vu dans ce chapitre les différentes techniques d'imagerie médicale pour explorer le corps humain, toutes ont leurs spécificités et elles sont indispensables à l'établissement d'un diagnostic sûr. Bien entendu, les techniques actuelles ne sont pas sans failles, sans passer par les pour et les contres de chacune, il est possible de dresser une liste globale des besoins toujours grandissants en imagerie:

- Meilleure qualité d'images (moins d'artéfacts et meilleur contraste).
- Plus grande vitesse d'acquisition (imagerie 4D en temps réel).
- Meilleure résolution des images (images plus détaillées et plus volumineuses).

Bien que les différentes techniques d'imagerie soient de plus en plus précises et rapides, il n'en demeure pas moins que le diagnostic et l'identification des données provenant de l'image sont encore en grande partie faits par les médecins. Des méthodes de reconnaissance d'organes/tissus par ordinateur permettraient, en plus de diminuer significativement le temps de réponse pour le patient, de diminuer également les possibles erreurs humaines. Dans les prochaines sections de ce document on va voir comment les méthodes mathématiques interviennent dans l'aide au diagnostic médicale.

II.1.Introduction

La description d'une image vise à produire un vecteur regroupant l'information extraite de l'image appelé descripteur. Ce descripteur traduit l'information d'une image sous forme plus compacte.

II.2.Descripteurs visuel utilisés

Le choix des descripteurs représentant le contenu d'une image est un critère qui détermine plus au moins la qualité de classification. Un bon choix peut mener à de bons résultats.

En médecine, la plupart des images médicales sont en niveau de gris. Pour cela, nous nous concentrons dans cette étude sur l'analyse de texture et de la forme. Ces descripteurs doivent en effet permettre au classifieur de discriminer les éléments pathologiques des éléments sains et être caractéristiques de chacune des classes.

II .2.1.Les descripteurs de textures

La texture peut être vue comme un ensemble de pixels (niveaux de gris) spatialement agencés selon un certain nombre de relations spatiales, ainsi créant une région homogène. De ces définitions, les recherches sur la modélisation des textures se sont portées sur la caractérisation de ces relations spatiales . De nombreuses approches et modèles ont été proposées pour la caractérisation de la texture. Parmi les plus connues, nous avons utilisé la matrice de cooccurrence, le filtre de Gabor et les ondelettes

II.2.1.1Matrice de cooccurrence[6]

La matrice de cooccurrence est un outil d'ordre deux (on ne parle pas ici d'ordre deux au sens moment comme la variance, mais du fait qu'on mesure des relations entre objets qui vont par paires, en l'occurrence des couples de pixels).La méthode de matrice de cooccurrence est largement utilisée dans le monde du traitement d'images (Haralick et al., 1973). Elle présente une grande simplicité de mise en œuvre et donne de bons résultats sur la plupart des types d'images. À partir d'une image représentée en niveaux de gris, il s'agit d'obtenir la matrice des moyennes d'espace du second ordre, appelée

matrice de cooccurrence. Cette matrice contient une masse très importante d'informations difficilement manipulable. C'est pour cela qu'elle n'est pas utilisée directement mais à travers des mesures dites indices de texture. En 1973, Haralick et al. ont proposé quatorze indices. Bien que corrélés entre eux, ces indices réduisent l'information contenue dans la matrice de cooccurrence et permettent une meilleure discrimination entre les différents types de textures. La difficulté à surmonter lors de l'application de cette technique réside justement dans le choix de ces paramètres car ils varient en fonction du type d'images et de textures. Parmi les quatorze indices proposés par Haralick, on a pris pour notre étude les plus utilisés à savoir : la variance, le contraste, l'entropie, l'homogénéité, la corrélation, l'énergie, l'uniformité et la directivité. L'information texturale extraite à partir de la matrice de cooccurrence est paramétrée par les grandeurs suivantes : le pas de déplacement δ , la direction suivant laquelle les deux pixels comparés est choisie .

Dans notre cas on s'intéresse aux descripteurs de texture suivants :

- **L'énergie :** Ce paramètre mesure l'uniformité de la texture. Il atteint de fortes valeurs lorsque la distribution des niveaux de gris est constante ou de forme périodique.

$$E = \sum_i \sum_j (P_{d,\theta}(i,j))^2 \quad (\text{II.01})$$

L'élément $(P_{d,\theta}(i,j))$ de la matrice de cooccurrence définit la fréquence d'apparition des couples de niveaux de gris i et j pour les couples de pixels séparés par une distance d selon la direction θ .

- **Contraste:** plus la texture est contrastée, plus ce terme est grand.

$$\text{CONT} = \sum_i \sum_j ((i,j)^2) (P_{d,\theta}(i,j)) \quad (\text{II.02})$$

- **Entropie:** faible si on a souvent les mêmes couples de pixels. C'est un indicateur de désordre.

$$\text{ENT} = - \sum_i \sum_j (\log P_{d,\theta}(i,j)) (P_{d,\theta}(i,j)) \quad (\text{II.03})$$

- **Homogénéité:** plus on retrouve le même couple de pixels, plus cet indice est élevé, par exemple image uniforme, ou texture périodique dans le sens de la translation

$$\text{HOM} = \sum_{i,j} \frac{1}{1+(i-j)^2} P(i,j) \quad (\text{II.04})$$

- **Corrélation:** décrit les corrélations entre les lignes et les colonnes de la matrice de cooccurrence.

$$COR = \sum_i \sum_j (i - u_x)(j - u_y)P(i, j) \quad (\text{II.05})$$

Avec : u_x et u_y ont respectivement les moyennes des lignes et des colonnes

- Directivité: ce coefficient est d'autant plus important que la texture possède une orientation privilégiée dans le sens de la translation.

$$Dir = \sum_{i=1}^n P(i, j, d, \theta) \quad (\text{II.06})$$

- Uniformité: d'autant plus élevé qu'un même niveau de gris apparaît dans la texture.

$$U = \sum_i \sum_j p(i, j, d, \theta)^2 \quad (\text{II.07})$$

- La variance : La variance mesure l'hétérogénéité de la texture. Elle augmente lorsque les niveaux de gris diffèrent de leur moyenne

$$Var = \sum_{i=1}^n \sum_{j=1}^m (i - u)^2 P(i, j, d, \theta) \quad (\text{II.08})$$

$$u = \frac{\sum_{i=1}^n \sum_{j=1}^m P(i, j, d, \theta)}{nm} \quad (\text{II.09})$$

u réfère à la moyenne mesuré pour le vecteur $p_x(i)$.

II.2.1.2. Les filtres de Gabor [7]

La texture est définie comme un mélange de signaux de fréquences, d'amplitudes et de directions différentes. Les méthodes fréquentielles consistent à extraire l'énergie portée par le signal dans diverses bandes de fréquence. Analyser une texture de part son spectre fréquentiel nous donne beaucoup d'informations sur celle-ci.

Un filtre de Gabor 2-D est produit d'une gaussienne elliptique dans toute rotation et un exponentiel complexe représentant une onde plane sinusoïdale. On rappelle que, dans le domaine spatial, la fonction de Gabor bidimensionnelle est une somme de deux fonctions sinusoïdales, l'une paire et réelle, l'autre impaire et imaginaire, modulée par une enveloppe gaussienne. Le filtrage correspond à une convolution par des filtres de réponse impulsionnelle de la forme suivante:

$$h(x, y) = A \exp \left\{ -\frac{1}{2} \left[\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2} \right] \right\} * \cos (2u_0 x \Pi + \Phi) \quad (\text{II.10})$$

u_0 représente la fréquence radiale du filtre.

σ_x et σ_y c'est les constantes spatial du filtre.

Φ la phase de la sinusoïde par rapport à l'axe x (il permet d'avoir un filtre paire ou impaire).

(x_0, y_0) coordonné du point où la gaussienne est maximale.

Ainsi

$$(x - x_0)' = (x - x_0) \cos(\theta) + (y - y_0) \sin(\theta)$$

$$(y - y_0)' = -(x - x_0) \sin(\theta) + (y - y_0) \cos(\theta);$$

θ c'est l'angle de rotation de $[(x - x_0)', (y - y_0)']$ par rapport à $(x - y)$, il donne l'orientation de l'enveloppe gaussienne $g(x,y)$ telle que :

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left\{-\frac{1}{2}\left[\frac{(x-x_0)^2}{\sigma_x^2} + \frac{(y-y_0)^2}{\sigma_y^2}\right]\right\} \quad (\text{II.11})$$

où σ_x et σ_y sont des constantes d'espace de l'enveloppe gaussienne qui déterminent l'étendue de l'onde suivant les axes x et y respectivement et (x_0, y_0) , le point d'origine où s'applique la fonction $h(x,y)$. En ce point, la fonction est maximale. Les coordonnées (x', y') se déduisent de (x, y) par :

où l'angle de rotation θ de (x', y') par rapport à (x,y) donne l'orientation de l'enveloppe gaussienne dans le domaine spatial.

La transformée de Fourier du filtre est donc donnée par :

$$H(U,V) = A \left(\exp\left(-\frac{1}{2}\left[\frac{(U-u)^2}{\sigma_u^2} + \frac{V^2}{\sigma_v^2}\right]\right) + \exp\left(-\frac{1}{2}\left[\frac{(U+u)^2}{\sigma_u^2} + \frac{V^2}{\sigma_v^2}\right]\right) \right) \quad (\text{IV.12})$$

Avec

$$A = 2\pi\sigma_x\sigma_y H(U, V) = A \left(\exp\left(-\frac{1}{2}\left[\frac{(U-u)^2}{\sigma_u^2} + \frac{V^2}{\sigma_v^2}\right]\right) + \exp\left(-\frac{1}{2}\left[\frac{(U+u)^2}{\sigma_u^2} + \frac{V^2}{\sigma_v^2}\right]\right) \right) \quad (\text{II.13})$$

A : module de la gaussienne.

U : fréquence radial central de filtre.

Où : $\sigma_u = 1/2\sigma_x$, $\sigma_v = 1/2\sigma_y$, σ_x et σ_y sont les déviations standards le long des axes x et y ,

u est la longueur d'onde sinusoïdale le long de la directions x (à 0° d'orientation).

Les caractéristiques qu'on peut extraire des filtres de gabor pour analysé la texture sont :

La moyenne :
$$\mu_{m,n} = \frac{E(m,n)}{M * N} \quad (\text{II.14})$$

Tel que :
$$E(m,n) = \sum_x \sum_y |H_{m,n}(x,y)| \quad (\text{II.15})$$

$H_{m,n}$: la transformée de fourrier de la gaussienne

Variance : La variance est une autre mesure de la dispersion d'un ensemble de données. Il s'agit tout simplement du carré de l'écart-type. La formule de la variance $\sigma_{m,n}^2$ est donc :

$$\sigma_{m,n} = \frac{\sqrt{\sum_x \sum_y (H_{m,n}(x,y) - \mu_{m,n})^2}}{M * N} \quad (\text{II.16})$$

Donc $v = \sigma_{m,n}^2$.

➤ Entropie =

$$\text{Ent} = \frac{1}{mn} \sum_i (H_{m,n}(x,y) \cdot \log(H_{m,n}(x,y))) \quad (\text{II.17})$$

Les fonctions de Gabor présentent les avantages suivants :

- Localisation maximale dans les espaces spatial et fréquentiel;
- Flexibilité: les fonctions de Gabor peuvent être positionnées librement et continuellement dans l'espace, des fréquences et des orientations choisies arbitrairement sans contraintes.

II.2.1.3. Les ondelettes [8]

fonction oscillante de moyenne nulle, appelée ψ , possédant un certain degré de régularité et dont le support est fini.

Exemples d'ondelette $\psi(t)$




Fig.1. ondelette de Haar




Fig.2. ondelette Daubechies

La transformée en ondelettes consiste à décomposer un signal en utilisant une famille de fonctions $\psi(x)$ obtenues par la translation et la dilatation d'une fonction mère $\psi_{u,s}$. Les ondelettes ((II.18)) sont générées à partir de cette fonction $\psi_{u,s}(t)$.

L'ondelette mère ψ génère une famille d'ondelettes :

$$\{\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-u}{s}\right)\} ; (u,s) \in \mathbb{R} * \mathbb{R}_0^+ \quad (\text{II.18})$$

u paramètre du temps et s paramètre d'échelle. L'ondelette $\psi_{u,s}$ est l'ondelette mère traduite de u et dilatée (contractée si $s < 1$) par s .

L'approche continue des ondelettes pour un signal 2D (image) est trop complexe pour être applicable rapidement sur des images. Pour résoudre ce problème, on considère l'analyse en ondelettes comme une décomposition du signal par une cascade de filtres, en utilisant une paire de filtres pour chaque niveau de résolution (un filtre passe-haut et un filtre passe-bas). Il

propose ainsi la DWT (Discrete Wavelet Transform) qui permet d'obtenir une transformée rapide. Le choix de l'ondelette mère est alors remplacé par le choix du filtre. Pour calculer une transformée en ondelettes, on n'a alors besoin que des deux filtres : au lieu de calculer le produit scalaire de l'ondelette avec le signal, on réalise un produit de convolution du signal avec ces filtres.

Typiquement, la transformée en ondelettes est représentée par deux filtres passe-bas et passe-haut, une image texturée donnée doit être décomposée, en 4 sous-images, qui peuvent être à leur tour décomposées en 4 sous-images. Plus précisément, si I est une image texturée de taille (n,m), les 4 sous-images obtenues après la transformation par ondelettes sont définies par :

$$D_1^1 = \sum_{i=1}^n h[i] \sum_{j=1}^m h[j]. I(2n - i, 2m - j) \quad (\text{II.19})$$

$$D_2^1 = \sum_{i=1}^n h[i] \sum_{j=1}^m g[j]. I(2n - i, 2m - j) \quad (\text{II.20})$$

$$D_3^1 = \sum_{i=1}^n g[i] \sum_{j=1}^m g[j]. I(2n - i, 2m - j) \quad (\text{II.21})$$

$$D_4^1 = \sum_{i=1}^n g[i] \sum_{j=1}^m h[j]. I(2n - i, 2m - j) \quad (\text{II.22})$$

(II.19) , (II.20) , (II.21) et (II.22) représente la décomposition de l'image texturé

Où h et g sont respectivement, deux filtres passe-haut et passe-bas

Après l'application des transformé de l'ondelette sur l'image. Pour l'extraction de la texture à partir de l'image nous calculons les paramètres suivants.

L'entropie :

$$H_s^q = \frac{1}{nm} \sum_{i=1}^n \sum_{j=1}^m D_s^q(i, j) \cdot \log(D_s^q(i, j)) \quad (\text{II.23})$$

La moyenne :

$$M_s^q = \frac{1}{nm} \sum_{i=1}^n \sum_{j=1}^m (D_s^q(i, j)). \quad (\text{II.24})$$

D'où D_s^q : est le résultat de la décomposition q de l'image I

s=1,2,3 ou 4 l'indice de l'image I

II.2.2. Les descripteurs de formes [9]

La forme est généralement une description très riche d'un objet. les attributs de forme sont généralement extraits après un processus de segmentation d'une image. bonne représentation de la forme d'un objet doit être invariante à la translation, la rotation et au redimensionnement. Sur le plan pratique ce n'est pas facile d'atteindre ce degré de fiabilité d'une description de la forme. nous distinguons deux catégories de descripteurs de formes : les descripteurs basés sur les régions et les descripteurs basés sur les frontières. Les premiers font classiquement référence aux moments invariants et sont

utilisés pour caractériser l'intégralité de la forme d'une région. Ces attributs sont robustes aux transformations géométriques comme la translation, la rotation et le changement d'échelle. La seconde approche fait classiquement référence aux descripteurs de Fourier et porte sur une caractérisation des contours de la forme. Pour extraire l'information pertinente de la forme, nous avons utilisé les moments géométriques permettant de décrire une forme à l'aide de propriétés statistiques. Ils représentent les propriétés spatiales de la distribution des pixels dans l'image. A partir des moments géométriques, Hu a proposé un ensemble de sept moments invariants aux translations, rotations et changement d'échelle. Ils sont très utilisés dans la littérature pour la description de formes en vue d'une classification ou d'une indexation, mais sont assez sensibles aux bruits. Par ailleurs cette famille de descripteurs n'est ni orthogonale, ni complète. Ces moments permettent de décrire la forme à l'aide de propriétés statistiques. Plusieurs techniques ont été développées pour la caractérisation et la représentation d'objets par ces moments. La formulation générale de ces moments géométriques dans le domaine continu est donnée par l'équation suivante :

$$M_{pq} = \iint x^p y^q f(x, y) dx dy \quad (\text{II.25})$$

où x et y sont des variables indépendantes d'une fonction f quelconque. Pour des images numérisées le moment d'ordre $(p+q)$ est donné par :

$$m_{pq} = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} i^p j^q f(i, j), \quad p, q = 0, 1, \dots, \infty \quad (\text{II.26})$$

où M et N sont respectivement la dimension horizontale et verticale de l'image et $f(i, j)$ l'intensité du point (i, j) dans l'image.

Le moment d'ordre 0, noté m_{00} est une valeur représentant la surface de l'objet et le rapport des moments d'ordre 1, notés m_{01} , m_{10} et m_{00} définissent le centre de gravité de la surface de l'objet. Il est calculé par l'expression suivante :

$$x_g = \frac{m_{10}}{m_{00}}, \quad y_g = \frac{m_{01}}{m_{00}} \quad (\text{II.27})$$

Ces moments de base sont d'utilité limitée puisqu'ils varient à chaque changement de l'origine, échelle et orientation de l'objet. Un ensemble de moments invariants serait plus utile. Ceci peut être dérivé en calculant d'abord les moments centrés par l'équation suivante :

$$\mu_{pq} = \sum_i \sum_j (i - x_g)^p (j - y_g)^q f(i, j) \quad (\text{II.28})$$

Les moments centrés sont utilisés pour le calcul des moments centrés normalisés : Ils sont calculés par l'expression suivante :

$$\eta_{pq} = \frac{\mu_{pq}}{s^{(p+q/2)+1}} \quad ; p + q \geq 2 \quad (\text{II.29})$$

où s représente la surface de l'objet. A partir des moments centrés normalisés, nous avons calculé un ensemble de sept paramètres invariants. Ces 7 moments invariants sont :

- Invariants du second ordre : Φ_1, Φ_2

$$\Phi_1 = \mu_{2,0} + \mu_{0,2} \quad (\text{II.30})$$

$$\Phi_2 = (\mu_{2,0} - \mu_{0,2})^2 + 4\mu_{1,1}^2 \quad (\text{II.31})$$

- Invariants du troisième ordre $\Phi_3, \Phi_4, \Phi_5, \Phi_6, \Phi_7$.

$$\Phi_3 = (\mu_{3,0} - 3\mu_{1,2})^2 + (3\mu_{2,1} - \mu_{0,3})^2 \quad (\text{II.32})$$

$$\Phi_4 = (\mu_{3,0} + \mu_{1,2})^2 + (\mu_{2,1} + \mu_{0,3})^2 \quad (\text{II.33})$$

$$\Phi_5 = (\mu_{3,0} - 3\mu_{1,2})(\mu_{3,0} + \mu_{1,2})[(\mu_{3,0} + \mu_{1,2})^2 - 3(\mu_{2,1} + \mu_{0,3})^2] + (3\mu_{2,1} - \mu_{0,3})(\mu_{2,1} + \mu_{3,0}) [3(\mu_{3,0} + \mu_{1,2})^2 - 3(\mu_{2,1} + \mu_{0,3})^2] \quad (\text{II.34})$$

$$\Phi_6 = (\mu_{2,0} - \mu_{0,2}) [3(\mu_{3,0} + \mu_{1,2})^2 - (\mu_{3,0} + \mu_{1,2})^2] + 4\mu_{1,1} (\mu_{3,0} - \mu_{1,2})(\mu_{2,1} - \mu_{0,3}) \quad (\text{II.35})$$

$$\Phi_7 = (\mu_{3,0} - \mu_{1,2})(\mu_{3,0} - \mu_{1,2}) [(\mu_{3,0} + \mu_{1,2})^2 - 3(\mu_{2,1} + \mu_{0,3})^2] - (\mu_{3,0} - 3\mu_{1,2})(\mu_{2,1} - \mu_{0,3}) [3(\mu_{3,0} + \mu_{1,2})^2 - (\mu_{2,1} + \mu_{0,3})^2] \quad (\text{II.36})$$

Dans notre travail, ces invariants sont extraits à partir des images binaires segmentée avec la méthode Otsu.

Le vecteur $V = (\Phi_1, \Phi_2, \Phi_3, \Phi_4, \Phi_5, \Phi_6, \Phi_7)$ constitue un vecteur d'entrées de FCM.

II.3. Conclusion

Dans ce chapitre, nous avons présenté les méthodes d'extractions des attributs d'une image, Vu que nos images sont en niveau de gris., nous nous concentrons dans cette étude sur l'analyse de texture et de la forme. On a vu que parmi ces méthodes les matrices de cooccurrence, la décomposition en ondelettes, les filtres de gabor et les moments invariant de hu pour l'analyse de la forme. les attributs extrait sont regroupé en vecteur et il seront l'entrée de notre algorithme de classification qui sera présenté dans le chapitre suivant

II.1.introduction

La classification consiste à regrouper des données en catégories les plus homogènes possibles, c'est-à-dire créer des classes contenant le plus des objets similaires. Parmi les méthodes utilisées pour la classification on trouve le c-moyennes, il est parmi les algorithmes qui se basent sur la minimisation d'une fonction objective. D'autres variantes de ces algorithmes ont ensuite été mises au point afin d'en accroître les performances, le plus populaire est l'algorithme FCM.

Nous présentons dans ce chapitre en premier, un panorama des méthodes de classification les plus connues, ensuite, nous décrivons l'algorithme FCM et certaines de ses variantes .

II.2.Définition de la classification [10]

D'un point de vue général, les méthodes de classification ont pour but de regrouper les éléments d'un ensemble $X=\{X^1, \dots, X^n, \dots, X^N\}$, en un nombre K optimal de classes selon leurs ressemblances [1]. De manière générale, les problèmes de classification s'attachent à déterminer des procédures permettant d'associer une classe à un objet (individu). Ces problèmes se déclinent essentiellement en deux variantes selon Bezdek[2]: la classification dite " supervisée " et la classification dite " non supervisée ". La classification, supervisée ou non, en tant que discipline scientifique, n'a été automatisée et massivement appliquée . Comme la plupart des activités scientifiques, l'essor des différentes techniques de classification a largement bénéficié de l'avènement et du perfectionnement des outils informatiques. Les méthodes de classification ont pour but de regrouper les éléments d'un ensemble X , de nature quelconque, en un nombre restreint de classes. La qualité de la classification peut être jugée sur la base des deux critères suivants :

- Les classes générées doivent être les plus différentes possibles les unes des autres vis-à-vis de certaines caractéristiques
- Chaque classe doit être la plus homogène possible vis-à-vis de ces caractéristiques.

La Figure suivante illustre le principe de la classification. Les données sont représentées par des points (vecteurs) dans un espace à n dimensions (dans notre exemple $n=2$). En sortie de la classification, on obtient c classes (ou familles) de points selon les critères donnés et le classifieur choisi (dans notre exemple, $c=3$).




Fig.1. Principe de la classification.

On parle de classification d'images lorsque les objets correspondent à des images où chaque image peut être caractérisée par un ensemble d'attributs tels que les attributs de couleur, de texture, ou de forme. La classification des images intervient comme étape très importante dans de différentes applications et surtout dans le domaine médical, elle permet d'aider les médecins à établir un diagnostic médical ou encore contrôler une action thérapeutique en lui offrant de nouveaux outils avec plus de précision et de performance.

II.3.Méthodes de classification [11]

De nos jours, la classification est une démarche qui est appliquée dans d'innombrables domaines, les méthodes utilisées sont nombreuses. Elles s'appliquent sur une grande quantité de données, et conviennent dans les problèmes de prise de décision automatique. Nous distinguons deux approches de classification : supervisé et non supervisé.

II.4.1.Méthodes supervisées

Une méthode supervisée consiste à définir une fonction qui attribue une ou plusieurs classes à chaque donnée. Dans cette approche on suppose qu'un expert fournit auparavant les étiquettes pour chaque donnée, les étiquettes sont des classes d'appartenance.

II.4.1.1.K-plus proches voisins [12]

La méthode des k plus proches voisins (en anglais k nearest neighbor) est une méthode de classification géométrique très utilisée, en raison de sa simplicité et de sa robustesse. Les descripteurs sont exploités dans un espace métrique de représentation, généralement \mathcal{R}^n muni d'une distance, particulièrement la distance euclidienne. La phase d'apprentissage consiste à stocker les images étiquetées. L'affectation de nouvelles images s'opèrent en calculant une distance entre les attributs de l'image à classifier et ceux de chaque image de la base. Les k

images les plus proches sont sélectionnées et l'image requête est assignée à la classe majoritaire (celle qui a le plus grand nombre d'individus). Cette technique facile à appliquer donne de très bons résultats mais pose un problème pour le choix de la valeur de k qui peut se faire aléatoirement ou bien expérimentalement. Une autre principale difficulté consiste à sa dépendance à une fonction de distance pertinente.

II.4.1.2. Réseaux de neurone [13]

Cette méthode repose sur la notion de neurone formel. Un neurone formel est un modèle caractérisé par des signaux d'entrée (les variables explicatives par exemple), une fonction d'activation f .

f peut être linéaire, à seuil, stochastique et le plus souvent sigmoïde. Le calcul des paramètres se fait par apprentissage.

Afin de traiter les problèmes de classification, on utilise les réseaux à couches. Les réseaux à couches sont connus sous le nom de perceptron multicouche. Ce sont des réseaux où les neurones sont regroupés en couches connectées entre elles. On distingue trois types de couches : la couche d'entrée, la couche de sortie et les couches cachées.

1-) Couches d'entrée : reçoit les données sources que l'on souhaite classer, dans notre cas les entrées sont les descripteurs de bas niveau (couleur, forme et texture).

2-) Couches cachées : ce sont des couches intermédiaires entre les couches d'entrée et les couches de sorties, elle reçoit les informations à partir des couches d'entrée et envoie aux couches de sortie, elle est utilisée dans le cas des réseaux de neurone multicouches.

3-) Couches de sortie : qui donne la réponse qui correspond à la simulation des données en entrée.

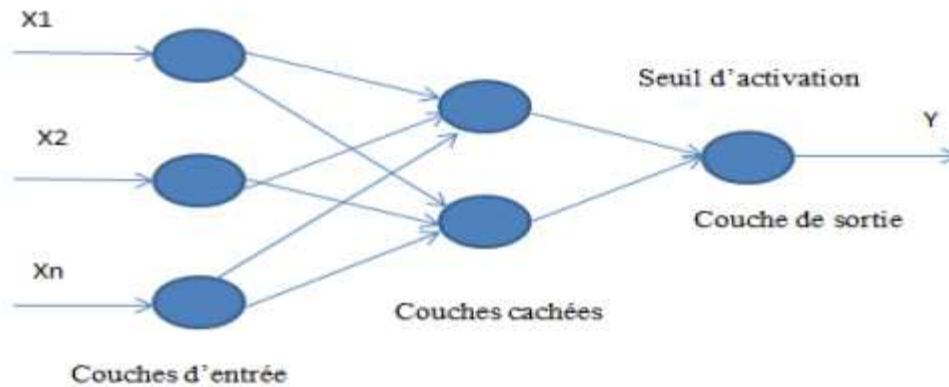


Fig.2.structure d'un réseau de neurone multicouche

Les perceptrons multicouches utilisent le principe de rétropropagation. L'avantage majeur d'utilisation des réseaux de neurones pour la classification est la facilité de mise en œuvre. Les inconvénients de cette méthode qu'elle nécessite une phase d'apprentissage et les résultats fournis à la sortie de réseau de neurones ne sont pas justifiés.

II.4.1.3.Algorithme de Bayes[14]

Cet algorithme de classification est basé sur la théorie de décision Bayésienne. La méthode utilisée est une approche statistique supposant que le problème de classification peut être exprimé en termes probabilistes. L'hypothèse de base est généralement que la fonction de densité de probabilité d'un objet x d'appartenir à une classe C_i est de forme gaussienne. L'algorithme de Bayes cherche à déterminer pour chaque élément x la classe C_i qui maximise la probabilité de contenir cet élément.

$$f(x, C_i) = -\frac{1}{2}(x - \mu_i)^T \Sigma_i^{-1}(x - \mu_i) - \frac{1}{2} \log |\Sigma_i| - \log p_i + \frac{k}{2} \log 2\pi \quad \text{III.01}$$

f : fonction objective

où k est le nombre de classes, μ_i la moyenne des éléments de la classe C_i , Σ_i la matrice de variance-covariance et p_i la probabilité a priori de la classe C_i .

II.4.1.4.Algorithme des Machines à vecteurs supports[15]

Les SVMs en anglais Support vector machine sont des nouvelles techniques de classification supervisée et d'apprentissage statistiques inventées par V.Vapnick en 1990, le succès de cette méthode est justifiée par sa solide théorie, cette méthode est bien

adaptée pour traiter les données de grande taille .L'objectif des SVM est de maximiser la marge de séparation entre les classes.

C'est un algorithme d'apprentissage faisant l'hypothèse que les éléments sont linéairement séparables s'ils sont préalablement projetés dans un espace à grande dimension adéquat. La projection est réalisée par l'utilisation de fonctions kernel $k(x_i, x_j)$. La fonction la plus utilisée est le noyau gaussien qui réalise cette projection de façon implicite .

$$k(x_i, x_j) = \exp\left(\frac{-\|x_i - x_j\|^2}{2\sigma^2}\right) \quad \text{III .02}$$

La phase d'apprentissage sert à trouver l'hyperplan optimal. La recherche du meilleur hyperplan de séparation peut alors se formaliser comme un problème de programmation quadratique sous contrainte linéaire. L'hyperplan fournit par les SVM est ainsi représenté comme une combinaison linéaire de certains exemples de la base d'apprentissage appelés vecteurs de support.

II.4.2.Méthodes Non Supervisées

L'intérêt des méthodes non supervisées (automatiques) est qu'elles ne nécessitent aucune base d'apprentissage et aucune tâche préalable d'étiquetage manuel. Les algorithmes non supervisés les plus répandus tendent à minimiser une fonction objective, dépendant de la distance de chaque objet aux prototypes (ou noyaux) des classes. Selon la certitude de la classification que nous voulons obtenir, et la relation entre les classes, nous pourrions distinguer plusieurs méthodes de classification non supervisées, les plus connues sont k-means , et FCM qui est utilisé dans notre travail et qui sera vu en détail dans la suite du chapitre .

II.4.2.1.La méthode des k -means [16]

II.4.2.1.1.Présentation

La méthode des k -means a été introduite par J. McQueen en 1971 et mise en œuvre sous sa forme actuelle par E. Forgy . De nombreuses variantes se sont succédées depuis afin d'étendre ses capacités de classification (séparations non linéaires) : *kernel k-means* (k -means basée sur des méthodes à noyaux), améliorer ses performances : *global-k-means* ,*k-Harmonicmeans* , automatiser le choix du nombre de clusters : *Gaussian-means*,*X-means*. Dans le cadre de la classification non supervisée, on cherche généralement à partitionner l'espace en classes concentrées et isolées les unes des autres. Dans cette optique, l'algorithme des k -means vise à minimiser la variance intra-classe, qui se traduit par la minimisation de l'énergie suivante :

$$E = \sum_{c \in D} \sum_{x \in c} (x - m_c)^2 \quad \text{III.03}$$

$$E = \sum_{c \in D} \min(x - m_c)^2 \quad \text{III.04}$$

avec C l'ensemble des clusters et pour chaque cluster c, x est un élément de c, m_c son centre (appelé noyau), « D » l'ensemble des données que l'on cherche à classer.

II.4.2.1.2.algorithme

La minimisation de l'énergie (III.03) peut se réaliser par une descente de gradient sur les noyaux dont les propriétés de convergence ont été étudiées par (III.04). Elle peut se traduire par les étapes suivantes :

1. Initialisation des noyaux.
2. Mise à jour des clusters.
3. Réévaluation des noyaux.
4. Itérer les étapes 2.et3,jusqu'à stabilisation des noyaux.

II.4.2.2.Méthodes hiérarchiques [17]

La classification hiérarchique consiste à effectuer une suite de regroupements en classes de moins en moins fines en agrégeant à chaque étape les objets ou les groupes d'objets les plus proches. Elle fournit ainsi un ensemble de partitions de l'ensemble d'objets approche utilise la notion de distance, qui permet de refléter l'homogénéité ou l'hétérogénéité des classes. Ainsi, on considère qu'un élément appartient à une classe s'il est plus proche de cette classe que de toutes les autres. Son principe est simple, initialement chaque objet forme une classe, soit n classes, donc on cherche à réduire ce nombre de classe $T < n$ itérativement de sorte que dans chaque étape on fusionne deux classes ensemble (Les deux classes choisies pour être fusionnées sont celles qui sont les plus "proches" en fonction de leur dissimilarité) ou ajouter un nouveau élément à une classe (un élément appartient à une classe s'il est plus proche de cette classe que de toutes les autres). La valeur de dissimilarité est appelée indice d'agrégation. Qui commence dans la première itération faible, et croîtra d'itération en itération. Parmi les

algorithmes plus connus de ce type :

- La classification ascendante hiérarchique

- La classification descendante hiérarchique

II.4.2.3. Algorithme des C-moyennes floues [18]

L'algorithme des C-moyennes floues (Fuzzy C-means) diffère peu de l'algorithme des k-moyennes. Il n'associe pas directement une classe C_i à une image mais plutôt un degré d'appartenance à une classe (compris entre 0 et 1). Il est basé sur l'optimisation d'un critère quadratique où la somme des écarts quadratiques intra-classes $J(m)$ telle qu'elle est définie dans l'équation ci-dessous doit être minimale. Les deux paramètres d'entrées de cet algorithme devant être définis au préalable sont respectivement le paramètre de flou m et le nombre de classes k (le nombre de classes doit être supérieur ou égal à 2).

$$J_m(U, v) = \sum_{k=1}^n \sum_{j=1}^c \mu_{ij}^m d^2(x_k, v_j) \quad \text{III.05}$$

dans notre cas on s'intéresse à la classification floue plus exactement à l'algorithme fuzzy c means.

II.5.FCM [19]

La classification floue est comparable à la classification par des méthodes dites « dures ». Cependant, à la différence de ces dernières qui associent chaque élément d'un jeu de données à une classe unique, la classification floue permet d'affecter chaque élément à toutes les classes selon des degrés de certitude variables, et cela toujours d'une manière non supervisée. Ce type d'affectation est basé sur la distance entre un élément et tous les centres de classes, distance également appelée fonction d'appartenance. La fonction d'appartenance a été introduite par Zadeh 1965[9], dans une des premières études sur les ensembles flous. La classification floue a été introduite pour la première fois par Ruspini 1969[10], qui a appliqué une théorie des ensembles flous à un algorithme de classification.

II.5.1. Définition

Fuzzy C-Means (FCM) est un algorithme de classification non-supervisée floue. Issu de l'algorithme des C-Moyens (C-means), il introduit la notion d'ensemble flou dans la définition des classes : chaque point dans l'ensemble des données appartient à chaque cluster avec un certain degré, et tous les clusters sont caractérisés par leur centre de gravité. Comme les autres algorithmes de classification non supervisée, il utilise un critère de minimisation des distances intra-classe et de maximisation des distances inter-classe, mais en donnant un certain degré

d'appartenance à chaque classe pour chaque point. Cet algorithme nécessite la connaissance préalable du nombre de clusters et génère les classes par un processus itératif en minimisant une fonction objective. La classification floue des objets est décrite par une matrice floue à n lignes et c colonnes dans laquelle n est le nombre d'objets de données et c est le nombre de classes.

II.5.2.Représentation matricielle d'une partition floue d'un ensemble discret [20]

Soit W_{cn} l'ensemble des matrices à c lignes et n colonnes dont tous les éléments appartiennent à l'intervalle $[0,1]$ et dont la somme des éléments d'une colonne quelconque vaut 1. Une matrice A appartenant à W_{cn} est donc telle que :

$$(\forall i), (\forall j), a_{ij} \in [0,1] \quad \text{III.06}$$

$$(\forall j), \sum_{i=1}^c a_{ij} = 1 \quad \text{III.07}$$

II.5.3.Le principe

Le principe général de FCM est de classer dans une première étape les points d'une façon aléatoire dans les différentes classes, puis en calculant à chaque fois la moyenne des points appartenant à la même classe, ajuste les centres (prototypes) de ces classes, et classe les points de nouveau dans les classes appropriées jusqu'à la stabilisation, c'est-à-dire jusqu'à ce que tous les points seront classés correctement.

II.5.4.Algorithme [21]

L'algorithme des c -moyennes floues effectue une optimisation itérative en évaluant de façon approximative les minimums d'une fonction d'erreur. Il existe toute une famille de fonctions d'erreur associées à cet algorithme qui se distinguent par des valeurs différentes prises par un paramètre réglable, m appelé indice de flou (fuzzy index) et qui détermine le degré de flou de la partition obtenue. Les FCM sont un cas particulier d'algorithmes basés sur la minimisation d'un critère ou d'une fonction objectif. Soit U une c -partition floue de X , et soit v le c -uplet :

$$v = v_1, v_2, \dots, v_c$$

où $\forall i, v_i \in \mathbb{R}_p$. La fonction objectif associée aux c -moyennes floues, J_m est définie par :

$$J_m(U, v) = \sum_{k=1}^n \sum_{j=1}^c \mu_{kj}^m d^2(x_k, v_j) \quad \text{III.08}$$

Pour tout i ($1 \leq i \leq c$), v_i est un vecteur à p composantes qui représente le centroïde de la i ème classe, et pour tout i et pour tout k ($1 \leq k \leq n$), où est $d^2(x_k, v_i)$ une norme associée à un produit scalaire défini dans \mathbb{R}^p (distance euclidienne). On peut aussi écrire :

$$d^2(x_k, v_i) = (x_k - v_i)^T A (x_k - v_i) \quad \text{III.09}$$

où A est une matrice $p \times p$ définie positive. Enfin, l'indice flou m , doit être strictement supérieur à 1 : $m \in]1, +\infty[$.

Le carré de la distance séparant un vecteur x_k d'un centre v_i , $d^2(x_k, v_i)$, est pondéré par la puissance même du degré d'appartenance de la donnée x_k à la classe i , J_m est donc une erreur quadratique généralisée et sa minimisation conduit, théoriquement à la partition optimale.

Les c -moyennes floues produisent une c -partition floue qui est une approximation de cette partition optimale de l'ensemble de données $X = \{x_1, x_2, \dots, x_n\}$. L'algorithme, dont la convergence a été étudiée par Bezdek [13] est le suivant :

- 1) Fixer le nombre de classes c tel que $2 \leq c < n$, n étant le nombre de données. Fixer une valeur pour m telle que $m > 1$. Choisir une norme de la métrique, $\| \cdot \|$ dans \mathbb{R}^p :

$d^2(x_k, v_i) = (x_k - v_i)^T A (x_k - v_i)$ où A est une matrice à p lignes et p colonnes définie et positive. Le plus souvent A est la matrice identité qui correspond à la distance euclidienne.

- 2) Initialiser la c -partition floue en donnant des valeurs quelconques (éventuellement les deviner dans la mesure du possible) aux éléments de la matrice de départ correspondante $U(0)$ vérifiant

$$\forall k \in \{1 \dots n\}, \sum_{i=1}^c \mu_{ik} = 1 \quad \text{III.10}$$

- 3) Initialiser le compteur de boucle : $b = 0$.
- 4) Calculer les c centroïdes de classe $\{v_i(b)\}$, $1 \leq i \leq c$, en utilisant $U(b)$ à l'aide de la formule suivante:

$$v_i = \frac{\sum_{j=1}^n \mu_{ij}^m x_j}{\sum_{j=1}^n \mu_{ij}^m} \quad \text{III.11}$$

- 5) Mettre à jour la matrice U : calculer la nouvelle matrice de degrés d'appartenance $U^{(b+1)}$ comme suit. Pour $k = 1$ allant jusqu'à n ,

a) Chercher I_k et:

$$I_k = \{i/1 \leq i \leq c \text{ et } d_{ik}(x_k - v_i)=0\} \quad \text{III.12}$$

$$l_k = \{1, 2, \dots, c\} - I_k \quad \text{III.13}$$

b) Pour la k ième donnée x_k , calculer les nouveaux degrés d'appartenance selon que l'on est dans l'un ou l'autre des deux cas suivants :

i) si $I_k = \emptyset$:

$$\mu_{ik} = \left\{ \sum_{j=1}^c \left(\frac{d^2(x_k, v_i)}{d^2(x_k, v_j)} \right)^{2/(m-1)} \right\}^{-1} \quad \text{III.14}$$

ii) Sinon pour tout $i \in I_k, \mu_{ik}=0$, et pour tout $i \in l_k$, fixer une valeur pour μ_{ik} de telle sorte que

$$\sum_{i \in I_k} \mu_{ik} = 1 \quad \text{III.15}$$

c) Incrémenter k et aller à l'étape a).

6) Comparer $U^{(b)}$ et $U^{(b+1)}$ à l'aide d'une norme matricielle : si $(U^{(b+1)} - U^{(b)}) < \varepsilon$

Arrêter l'algorithme, sinon, incrémenter b et aller à l'étape 4).

ε est un nombre réel prédéfini par l'utilisateur et qui sert dans le critère d'arrêt 6) basé sur la distance séparant la matrice calculée à l'itération au rang (b + 1) de celle calculée au rang(b).

II.5.5. Convergence des c-moyennes floues (FCM) [22]

Le critère d'arrêt le plus souvent utilisé consiste à comparer la fonction d'objectif J_m obtenue après une itération avec la fonction d'objective précédente. Si la différence est inférieure à un seuil prédéfini, alors le critère d'arrêt est satisfait. En pratique, il se peut que ce critère d'arrêt soit difficilement atteint (du point de vue temps de calcul). Pour cette raison, un deuxième critère d'arrêt, qui consiste à imposer un nombre maximal d'itérations, est couramment utilisé. L'algorithme s'arrête donc quand l'un de ces deux critères est atteint. Remarque : dans notre étude, l'algorithme FCM a été appliqué en choisissant une valeur de 10^{-5} pour l'amélioration de la fonction d'objectif entre deux itérations consécutives et un nombre maximal de 500 itérations. Dans tous les cas, le premier critère a été satisfait ; la convergence ne nécessitant pas un grand nombre d'itérations.

II.5.6. Paramètres de FCM [23]

L'algorithme FCM nécessite le choix a priori par l'utilisateur du nombre de classes K . De plus, l'utilisateur doit définir un deuxième paramètre à l'entrée de l'algorithme, paramètre connu sous le nom de paramètre de flou m . Ce paramètre contrôle le degré de flou, c'est-à-dire le degré d'appartenance de chaque élément de l'ensemble aux classes. Avec $m = 1$, la classification FCM est comparable à la classification dure. Quand m augmente, les degrés d'appartenance aux classes deviennent de plus en plus flous. Lorsque m tend vers l'infini, chaque élément a des degrés d'appartenance uniformément répartis entre toutes les classes. Cela crée des images des classes redondantes dans lesquelles seulement quelques pixels se différencient d'une classe à l'autre. En n'ayant aucune base théorique pour la sélection d'un paramètre optimal m , une valeur de $m = 2$ est couramment utilisée dans la littérature .

Un choix optimal du paramètre de flou m , parallèlement au choix du nombre de classes K , est nécessaire afin d'exploiter pleinement l'information contenue dans les images . Ce problème reste toujours un problème ouvert, surtout dans des applications biomédicales. si K et m sont pas choisi de façon optimale, les résultats de la classification FCM apparaissent moins efficaces par rapport aux résultats de classification « dures » .

II.7. Conclusion.

Pour l'algorithme des c-moyennes flous, la décision d'appartenance d'un objet à une classe n'est prise qu'à la fin de la convergence, sa nécessité la connaissance au préalable du nombre de classes, les résultats de FCM ne semblent pas très stables et cela à cause de la sélection aléatoire des centres c 'est pour ça que Plusieurs travaux ont présenté quelques variantes de FCM pour contrer ses effets. Certaines variantes visent à réduire l'influence des points d'appartenance faible aux clusters, en utilisant une métrique plus robuste que la métrique euclidienne. le FCM a été utilisé dans plusieurs application, dans notre travail on va utiliser l'algorithme FCM pour classifier des images médicales plus précisément des images cérébral en deux classes seins et malade, c'est l'objet du chapitre suivant.

IV.1.Introduction

Le but visé de ce chapitre est d'évaluer et de tester la performance des différents descripteurs utilisés dans la phase d'extraction de la texture et de la forme en terme de classification avec la méthode FCM. Nous allons présenter les résultats obtenus d'une série du test effectué sur les descripteurs texture et forme extraits à partir des images IRM cérébrale saines et pathologiques et nous proposons, en outre, leur combinaison pour une classification plus efficace et plus discriminante.

IV.2.La base d' images utilisé pour la classification

Nous avons travaillé sur des images téléchargées de l'internet [1], la Base contient 73 images IRM cérébrales en pondération T1 et de taille 256*256, divisées en images saines et images pathologiques.




Fig.1. Exemple d'images de la base utilisée(a)images seines (b) images pathologiques

IV.3.Critères de performances

Les performances de FCM implémenté ont été évaluées par le calcul du pourcentage de sensibilité (SE), la spécificité (SP) et taux de classification (TC), les définitions de ces derniers sont respectivement comme suit :

- Sensibilité (Se%) : $[Se = 100 * VP / (VP + FN)]$ on appelle sensibilité (Se) du test sa capacité de donner un résultat positif quand la maladie est présente. Représente ceux qui sont correctement détectés parmi tous les événements réels.
- Spécificité (Sp %) : $[Sp = 100 VN * / (VN + FP)]$ on appelle spécificité du test cette capacité de donner un résultat négatif quand la maladie est absente.
- Taux de classification (CC %) : $[CC = 100 * (VP + VN) / (VN + VP + FN +FP)]$ est le taux de reconnaissance.

FN (Faux Négatif) : désigne un test négatif dans un individu atteint d'une maladie.

FP (Faux Positif) : désigne un test positif dans un individu sain.

VN (Vrai Négatif) : désigne un test négatif dans un individu sain.

VP (Vrai Positif) : désigne un test positif dans un individu atteint d'une maladie.

Un bon test de diagnostic minimise le nombre de FN et de FP.

IV.4. Tests et résultats :

Nous présentons dans cette partie quelques exemples de résultats expérimentaux obtenus à partir d'application de FCM sur notre base d'images avec les différentes caractéristiques, et nous avons testées une combinaison de ces dernières afin d'améliorer les résultats. Les tests ont été implémentés avec **MATLAB** version **7.9 (R2009b)** sous l'environnement Windows7, et exécutés sur un Pc Acer Nplify 802.11b/g/n.

IV.4.1. Résultats de classification avec les descripteurs de texture :

IV.4.1.1. Matrice de cooccurrence

Nous avons utilisé 08 descripteurs mentionnés ci-dessus, calculés à partir de la matrice de cooccurrence dans les quatre directions.

Le tableau suivant donne quelques valeurs d'attributs de 04 images de la base d'images utilisé.

	Image1	Image2	Image3	Image4
Contraste	438,3925	619,8682	3957,5657	4089,4719
Corrélation	0,0001	3,9088e-05	8,6685e-05	7,3030e-05
Homogénéité	0,5503	0,5354	0,5862	0,6614
Entropie	-0,4535	-0,1896	-0,5892	-0,6377
Directivité	0,5422	0,5276	0,5818	0,6578
Uniformité	0,2640	0,2387	0,2908	0,3753
Energie	0,2642	0,2389	0,2923	0,3757
Variance	5616,2320	8642,0682	8362,3018	7901,7780

Tableau O1. Quelques valeurs d'attributs de 04 images de la base

Les résultats de l'évaluation du classifieur en termes de taux de classification, sensibilité et spécificité sont représenté dans l'histogramme, sachant que les données contiennent 58 images saines et 13 images pathologiques (images IRM cérébrale coupe axiale).

n : nombre d'itération

Les résultats de la classification avec la matrice de cooccurrence sont illustrés dans le tableau suivant:

	VP	FP	VN	FN	Tc	Se	Sp	n
C=2, m=2	51	13	7	0	90.1408	87.931	100	14

Tableau 02.Résultats de la classification avec la matrice de cooccurrence




Fig.2. Histogramme des performances obtenu avec la matrice de cooccurrence

On a eu des résultats assez bons avec un taux de classification atteignant les 90.1408% où la reconnaissance des images saines est de 51/58 et les images pathologiques 13/13. Le nombre des cas mal classés (Faux Positif=6), peut être expliqué par les chevauchements constatés dans certains paramètres tel que l’homogénéité et la directivité, (tableau 01). On remarque que l’algorithme a reconnu toutes les images malades comme malade (spécificité égal a 100%).

L’algorithme FCM a des difficultés à représenter des groupes de petites tailles, la base d’images est limitée.

➤ *L’influence des paramètres de la matrice de cooccurrence sur la classification*

Afin de choisir avec certitude les paramètres qui vont être pris pour la suite de notre travail, une série de classifications a été effectuée, comme dans le cas précédent. La comparaison des différents taux de classification nous a permis de confirmer l’analyse visuelle des canaux de texture. En effet, en ce qui concerne l’orientation, celle ci

n'apporte pas un grand changement à la performance de la classification. Pour cette raison et pour des raisons de rapidité de calcul, il a été jugé suffisant de prendre une seule direction, et un pas de déplacement d'un pixel. C'est donc ces paramètres qui vont être retenus pour la suite du traitement.

IV.4.1.2.Ondelettes

Un aspect très important dans l'analyse des objets est leur représentation. On désire souvent représenter ces objets de telle façon que les informations qu'on veut extraire soient facilement accessibles. Pour aboutir à une classification capable de bien identifier les différentes classes, il est nécessaire de disposer d'une représentation qui permet une extraction d'indices capables de minimiser les confusions entre les différentes classes. Du fait que les ondelettes sont sensibles aux variations spatiales d'un signal et peuvent isoler des détails à des échelles données, on peut alors considérer que les images des coefficients d'ondelettes constituent une nouvelle représentation de l'image dans laquelle l'information texturale est facilement accessible.

➤ Calcul des indices de texture

On a choisi l'entropie et la moyenne pour caractériser la texture dans le plan spatio-fréquentiel.

		Image1	Image2	Image3	Image4
L'entropie pour chaque face	ond	1.4491	1.4697	1,8818	1,1870
	Hr	1.5193	1.5685	1,9717	1,0727
	vs	1.3854	1.4247	1,9890	1,0591
	dg	1.8262	1.8810	2,1901	1,1552
la moyenne pour chaque face	ond1	79.6415	100.6860	25,4602	22,4633
	hr1	-0.1529	-0.2010	0,0313	-0,01444
	vs1	-0.0020	0.0472	0,00364	-0,0074
	dg1	-0.0009	-0.0113	0,0116	0,02420

Tableau.3 les valeurs des indices de texture extrait avec les ondelettes

8 attributs Moyenne et entropie des images qui correspondent aux détails : vertical, horizontal , diagonal et de l'image d'approximation .

	VP	FP	VN	FN	Tc	Se	Sp	n
C=2,m=2	52	13	6	0	91.5493	89.6552	100	14

Tableau.4 Résultats de la classification avec les ondelettes




Fig.3. Histogramme qui représente les performances obtenu avec les ondelettes

On constate une légère amélioration lorsqu'on utilise la méthode des ondelettes avec un taux de classification atteignant 91.5493%

IV.4.1.3.Filtre de Gabor

Les paramètres de texture utilisée pour le filtre de Gabor sont : la moyenne, l'énergie et la variance des niveaux de gris de l'image filtrée par Gabor.

	Moyenne(m)	entropie(e)	Variance(v)
Image1	0.2807	5.6536	0.3101
Image2	0.3190	5.8497	0.3394
Image3	0.1249	5.9156	0.1212
Image4	0.1106	4.3043	0.1227

Tableau.5 les valeurs des attributs de texture extrait par le filtre de Gabor

	VP	FP	VN	FN	Tc	Se	Sp	n
C=2,m=2	51	13	7	0	90.1408	100	87.931	17

Tableau.6 Résultats de la classification avec le filtre de gabor.

En terme de classification le taux reste inchangé, les paramètres de filtre de gabor n'influence pas la classification.

IV.4.2.Résultats de classification avec les descripteurs de forme :

IV.4.2.1.Moments de Hu

Les moments de Hu (1962) sont invariants par translation, rotation et échelle. Ils sont calculés à partir des moments géométriques centrés normalisés d'ordre 3 au plus. Les moments géométriques centrés d'ordre (p,q) s'expriment de la façon suivante :

$$\mu_{p,q} = \sum_x \sum_u (x - x_0)^p (y - y_0)^q I(x, y)$$

avec (x0,y0) les coordonnées du centre de l'image, I(x,y) la valeur du pixel au point de coordonnées (x,y). Les moments de Hu s'expriment de la façon suivante :

Les moments de Hu offrent d'excellents attributs invariants en translation, rotation et Changement d'échelle pour décrire une image. Cependant leur calcul est relativement long et Ils sont très sensibles au bruit, ce qui peut s'avérer être un gros inconvénient.

	Image1	Imge2	Image3	Image4
M1	0,3724	0,3772	0,3503	0,3307
M2	9,5195e-05	0,0002	0,0002	0,0062
M3	0,0007	0,0007	0,0012	6,86311e-05
M4	0,0007	0,0009	0,0002	1,7048e-05
M5	1,3778e-07	3,2842e-07	5,9745e-08	-1,1743e-10
M6	6,8940e-06	1,5869e-05	3,0244e-06	1,14226e-06
M7	-6,0396e-07	-7,8594e-07	-2,7681e-08	1,9200e-10

Tableau.7.La valeur des moments invariants de Hu (ordre 3)

L'extraction des moments invariants de hu prend un temps considérable.

Le résultat de classification avec les descripteurs de forme avec les moments invariants de hu :

	VP	FP	VN	FN	Tc	Se	Sp	n	obj
C=2,m=2	47	8	11	5	77.4648	81.0345	61.5385	9	0.025197

Tableau.8. Résultats de la classification avec les moments invariants de hu




Fig.4. Histogramme qui représente les performances obtenu par les moments de hu

Le résultat de classification en utilisant les moment invariant de hu n'est pas satisfaisante a comparant avec ceux de texture avec un taux de 77.4648% .

- la combinaison des attributs de texture n'apportent pas de changement aux performances de l'algorithme, le résultat est tiré a partir de la meilleur méthode descriptive dans notre cas c'est les ondelettes

IV.4.2.Résultats avec la combinaison la texture et la forme

- hu avec les ondelettes (entropie de chaque face)

	VP	FP	VN	FN	Tc	Se	Sp	n	Obj
C=2,m=2	58	9	0	4	94.3662	100	69.2308	16	7.85307

Tableau.9. Résultats de la classification avec la combinaison des ondelettes avec les moments invariants de hu

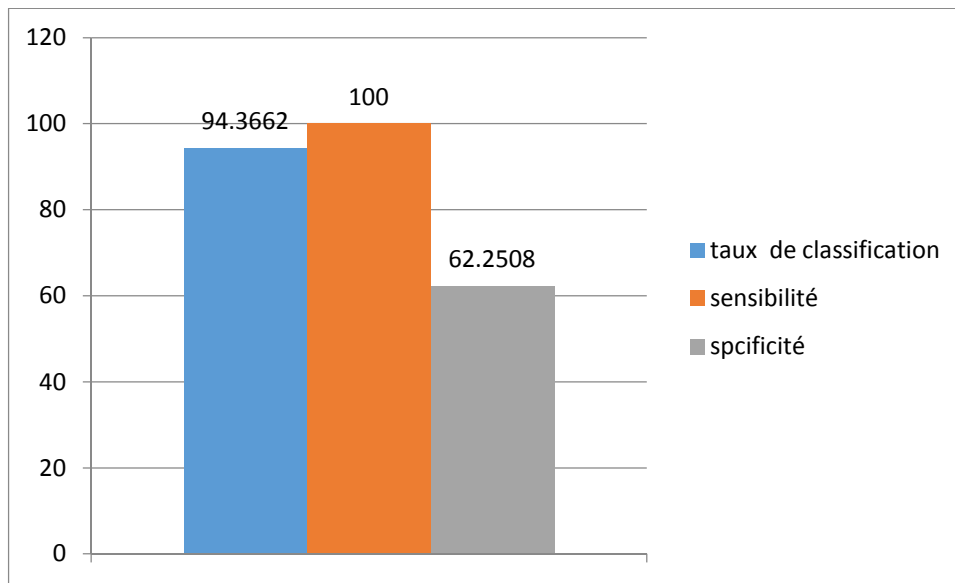


Fig.5. Histogramme qui représente les performances obtenu par hu avec les ondelettes

Lorsque on a combiné les moment invariant de hu avec les attributs extrait des ondelettes ,le taux de classification augmente considérablement de (16.9014%), donc on conclu que les descripteurs de forme sont plus robuste lorsque on les combine avec les descripteurs de texture.

Remarque :Les moments invariants de hu n'apportent pas de changement au taux de reconnaissance lorsque on les combine avec les indices de texture tiré soit de la matrice de cooccurrence ou bien de filtre de Gabor .

IV.5. choix des paramètres de FCM

IV.5.1. nombre de classe « c »

Il existe de nombreux critères pour le choix du nombre de clusters c ; nous le déterminons en utilisant la propriété de stabilité des FCM : lorsque c est inférieur ou égal au nombre de clusters naturels présents dans les données, les FCM convergent vers la même configuration associée à une même valeur du coût J ,indépendamment de l'initialisation aléatoire ; dans notre cas ce c'est pas possible de vérifié de moment que ce n'est pas permet de prendre le nombre de classe inférieur a 2.

lorsque c est supérieur, les FCM exploitent les degrés de liberté non contraints par les données et on observe une instabilité de la positionnes centres et de la valeur de coût. Pour un c fixé, la stabilité est mesurée par $C_{stab} = \sigma(J) / J$, quotient entre l'écart-type de

l'erreur et sa moyenne, lorsqu'on varie l'initialisation ; la valeur de c choisie est la plus grande valeur permettant un comportement stable.

IV.5.2. Influence de paramètre flou sur la classification

Le coefficient flou m qui est important dans la classification, fera l'objet d'un ensemble de test pour choisir la valeur optimale. Les critères de proximité employés pour la classification, sont des distances entre les attributs.

Après avoir effectué plusieurs tests en changeant la valeur de m la performance atteint avec les filtres de Gabor et la matrice reste inchangé

➤ Les ondelettes

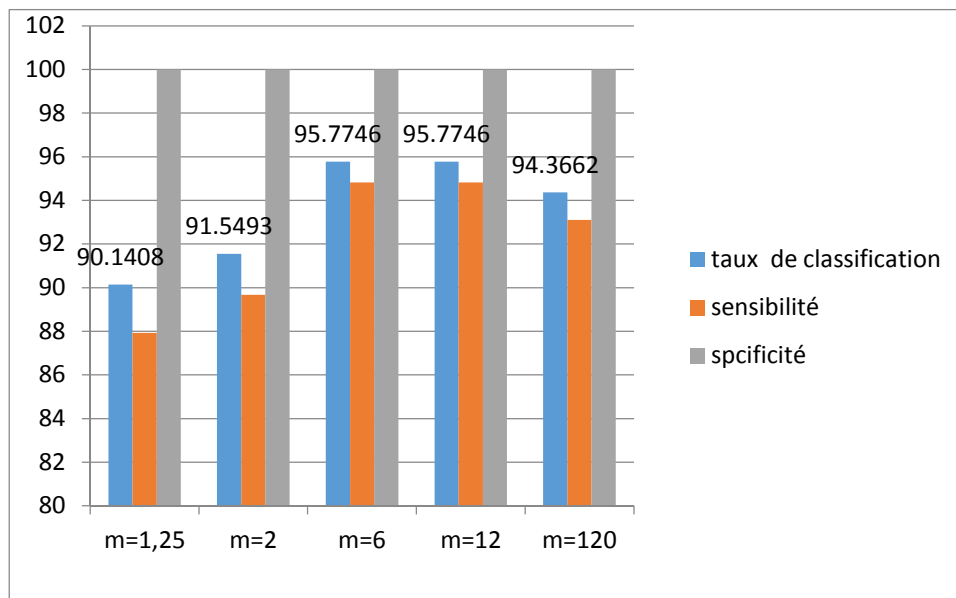


Fig.6. Histogramme qui représente les performances obtenu avec les ondelettes

on constate qu'on obtient un relation proportionnel entre le taux de classification et le facteur de flou mais juste dans des bande, m=1.25 jusqu'à m=6 le taux de classification augmente , entre m=6 et m = 12 le taux de classification est stable 95.7746% au delà de cette limite de m le taux de classification se dégrade jusqu'à a voir des valeurs nulle pour m infiniment grande.

Les meilleurs performances de l'algorithme FCM sont obtenues lorsque le facteur flou varié entre 6 et 12 pour toutes les méthodes descriptive.

Conclusion

Dans ce chapitre nous avons présenté les différents essais opérés afin d'évaluer la capacité de l'algorithme FCM pour classifier les images d'IRM cérébrales en deux classes saines ou pathologiques.

Pour chaque méthode d'extraction d'attribut (texture ou forme) on a eu de bons résultats mais la meilleure méthode c'est la combinaison des ondelettes avec les invariants de Hu, en choisissant le facteur m entre 6 et 12 ; ce qui nous permet de valider cette approche comme méthode analysé les images IRM.

Conclusion générale

Le sujet abordé dans ce mémoire s'inscrit dans un contexte médical, Ou la vision par ordinateur pour la décision automatique.

L'objectif de notre travaille est de concevoir un système d'aide au diagnostique plus précisément la classification des images médicales, pour cela on a utilisé le classifieur flou le c moyenne flou.

Notre étude est partagée en deux parties, dans un premier temps on a utilisé des différentes caractéristiques des images a savoir les caractéristiques de texture et de forme qui vont être l'entrée de notre classifieur. Après avoir fait plusieurs tests pour choisir la meilleure méthode descriptive. la combinaison des attribut de la transformée en ondelette avec les moments invariants de hu donne le plus grand taux de classification (95,7746%) et ce taux est très e encourageant et très prometteur.

On a constaté que le facteur flou m influence les performances des algorithmes, en choisissant la bonne valeur on obtient de bon résultat.

En perspective de ce travail, la méthode FCM peut être utilisé avec d'autre méthode de classification tel que les réseaux de neurone ou les algorithmes génétiques afin d'améliorer le taux de classification.

La logique floue

La plupart des systèmes non linéaires sont modélisables sous des hypothèses parfois très restrictives. Ces hypothèses, rendent difficiles la mise en œuvre des schémas de commande résultants et leur application. Il est donc nécessaire de prendre en compte toutes les informations imprécises et incertaines relatives au système. La théorie des sous ensembles flous développée par Lotfi A. Zadeh en 1965, a permis de traiter les imprécisions et les incertitudes. De nombreuses applications sont alors développées dans divers domaines, là où aucun modèle déterministe n'existe ou n'est possible d'obtenir.

Les fonctions d'appartenance

Une fonction d'appartenance d'un ensemble flou A définie sur l'univers de discours X, notée $\mu_A(x)$ tel que $x \in X$, est une courbe qui définit comment chaque point dans l'univers de discours est tracé avec une valeur d'appartenance comprise dans l'intervalle [0, 1]:

$$\mu_A(x) : X \rightarrow [0,1]$$

$$x \rightarrow \mu_A(x)$$

La valeur $\mu_A(x)$ mesure l'appartenance ou le degré avec lequel un élément x appartient à l'ensemble A. Il n'y a pas de règle précise pour la définition de fonction d'appartenance. Alors, chaque ensemble flou peut être représenté par sa fonction d'appartenance. Les fonctions d'appartenance peuvent être symétriques, régulièrement distribuées ou avoir une distribution non uniforme. En général, la forme des fonctions d'appartenance dépend de l'application et de la grandeur à modéliser et peuvent avoir différentes formes :

- Fonction triangulaire

$$\mu(x) = \begin{cases} \frac{a-x}{a-b} & \text{si } x \in [a, b] \\ \frac{b-x}{b-c} & \text{si } x \in [b, c] \end{cases}$$

01




Fig.1. Graphe d'une fonction triangulaire

- Fonction gaussienne

$$u(x, m, \sigma) = e^{-\left(\frac{x-m}{2\sigma}\right)^2} \quad \mathbf{02}$$

m : centre de la gaussienne et σ : sa largeur




Fig.2. Graphe d'une fonction gaussienne

- Fonction trapézoïdale

$$\mu(x) = \begin{cases} \frac{a-x}{a-b} & \text{si } x \in [a, b] \\ 1 & \text{si } x \in [b, c] \\ \frac{d-x}{c-d} & \text{si } x \in [c, d] \end{cases} \quad \mathbf{03}$$




Fig.3. Graphe d'une fonction trapézoïdale

4. Système flou

Généralement, un système à base de règles floues se compose de trois modules successifs:

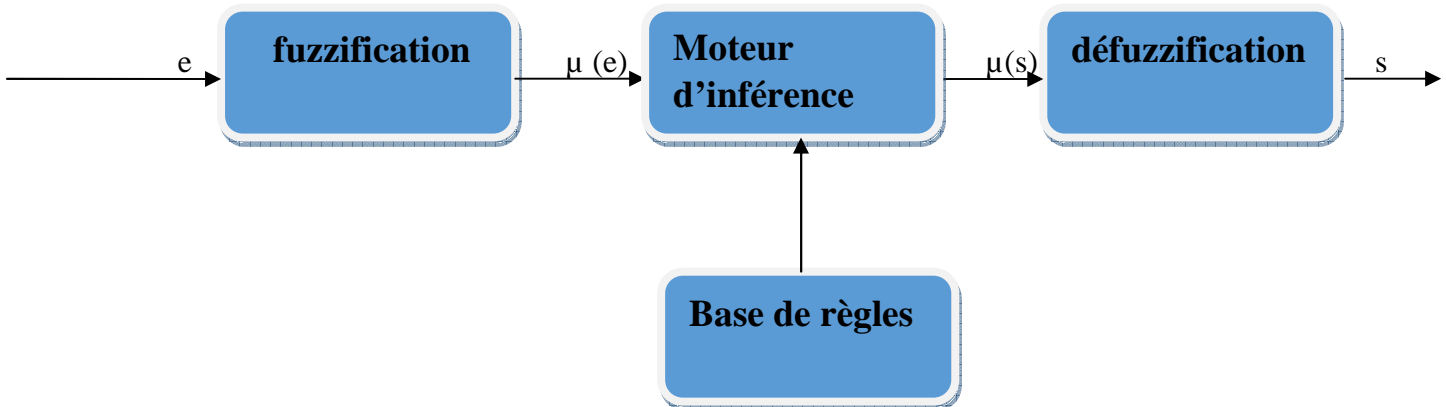


Fig.4. Schéma d'un système flou.

Où e représente le vecteur des entrées, s celui de la sortie, $\mu(e)$ et $\mu(s)$ les fonctions d'appartenance correspondantes.

- Le premier module traite les entrées du système, on définit tout d'abord un univers de discours, un partitionnement de cet univers en classes pour chaque entrée, et des fonctions d'appartenance pour chacune de ces entrées (exemple : pression, petite, faible). La première étape, est appelée fuzzification, consiste à attribuer à la valeur réelle de chaque entrée, au temps t , sa fonction d'appartenance à chacune des classes préalablement définies, donc à transformer l'entrée réelle en un sous-ensemble flou.
- Le deuxième module consiste en l'application de règles de type « si l'écart de température est grand, diminué le débit du fuel ». Ces règles permettent de

passer d'un degré d'appartenance d'une grandeur réglant aux degrés d'appartenance d'une commande. Ce module est constitué d'une base de règles et d'un moteur d'inférence qui permet le calcul.

- Le troisième et le dernier module décrit l'étape de defuzzification qui est la transformation inverse de la première. Il permet de passer d'un degré d'appartenance d'une commande à la détermination de la valeur à donner à cette commande.

4.1.fuzzification

La fuzzification consiste à définir des fonctions d'appartenance pour les différentes variables linguistiques. Ceci a pour but la conversion d'une grandeur physique en une linguistique. Cette opération permet d'avoir une mesure précise sur le degré d'appartenance de la variable d'entrée à chaque ensemble flou.

4.2.Interface d'inférence floue

L'interface d'inférence est formée de deux blocs :

- La base de règles, composé d'un ensemble de relations liant les variables d'entrées aux variables de sorties du système à régler.
- Le moteur d'inférence réalise le traitement numérique des règles d'inférence.

4.3.La défuzzification

Une défuzzification est une transformation d'une information floue en une information déterminée. Parmi les méthodes de défuzzification, on cite la méthode du maximum et la méthode du centre de gravité.

La méthode du maximum

Elle consiste à choisir comme solution défuzzifiée l'abscisse du maximum de la Fonction d'appartenance des solutions. Si plusieurs points conviennent, on peut par exemple utiliser une variante, la méthode de la moyenne des maxima, qui consiste à prendre comme solution la moyenne des abscisses des maxima. L'avantage de cette méthode est qu'elle ne nécessite pas une grande puissance de calcul.

Le centre de gravité

Cette méthode est la plus souvent utilisée et donne généralement les meilleurs résultats. Elle consiste à prendre comme solution l'abscisse du centre de gravité des solutions. Par comparaison avec la méthode du maximum, elle exige une plus grande puissance de calcul.

Représentation des objets par des sous-ensembles flous

Les applications des sous ensembles flou dans le domaine médicales se portent en général sur la classification de tissus, ou la classification en deux catégories : sain et pathologique. Dans ce contexte, les opérateurs de la théorie des sous-ensembles flous est peu exploités, puisque la décision revient juste à attribuer une classe par objet. Ce qui peut être fait directement en observant les degrés d'appartenance. Un des premiers algorithmes visant à représenter des connaissances imparfaites par des sous-ensembles flous et appliqué dans le domaine médical est l'algorithme des C-moyennes floues (ou FCM, pour Fuzzy C- means), Cet algorithme prend directement en compte le fait que les images elles-mêmes peuvent être considérées comme des scènes floues, où les objets apparaissent avec des frontières imprécises, Le FCM réalise une classification des données telles que les classes sont représentées par des sous-ensembles flous. Il construit donc leur fonction d'appartenance en calculant le degré d'appartenance de chaque objets aux différentes classes possibles L'avantage principal de cette méthode est son caractère non supervisé, qui ne nécessite pas de base d'apprentissage. Cependant, les fonctions d'appartenance calculées peuvent avoir une forme difficile à adapter pour certaines. De plus, le résultat est fortement dépendant de l'initialisation. L'étude vise à classifier les tissus sains et pathologiques. dans le chapitre qui suit on va détaillé la méthode de fcm et exploré ses paramètres.

Référence bibliographique

- [1] Olivier Ernst « Les rayons X » support de cours, Université Lille
- [2] imagerie médicale. Traitement des images polytech'orléans, 2005-2006
- [3] Support de cours « LES ULTRASONS EN MÉDECINE », Biophysique et Imagerie Médicale, Faculté de Médecine de LILLE.
- [4] RIBEIRO José AOUIJ Mohamed BOUCHEZ Romain
IMAGERIE MEDICALE FUSION D'IMAGES SIG ET TEL 2002/2003
- [5] Dispositifs d'imagerie médicale Master Images, Sciences et Technologies de l'Information
Noblet Intervenants : A. Daurat, V. Noblet, F. Rousseau
- [6] [HARA79] R.M. Haralick, "Statistical and structural approaches to texture", Proceedings of the IEEE, mai 1979, number 5, vol.67.
- [7] rabia nassim revue de la segmentation d'image texturé : cas des images couleur université
mouloud Mammeri 2011
- [8] Kimcheng KITH Contribution à la description des formes par la transformée en ondelettes
17 Mai 2004 université de La Rochelle UFR Sciences
- [9] Cédric Lemaître Rapport de stage DEA Instrumentation et Informatique de l'image
Utilisation de masques binaires dans une rétine de reconnaissance de formes Université de
Bourgogne Juin 2005
- [10] C Lurette, " Développement d'une technique neuronale auto-adaptative pour la
classification dynamique de données évolutives. Application à la supervision d'une
presse hydraulique.", Thèse, Université des sciences et technologies de LILLE 2003.
- [11] J Bezdek, "Pattern Recognition with Fuzzy Objective Function Algorithms", Plenum
Press, New York, 1981.
- [12] D. MICHIE, D. SPIEGELHALTER & C. TAYLOR. « Machine learning, neural and
statistical classification ». vol. 6, pages 84–106, 1994.
- [13] Abdel Hakim. Bourmel, " Apprentissage Neuro-Flou ", Thèse de
Magister, Département de Informatique Université Mentouri Constantine. Septembre 2001.
- [14] Cyril Meurie .Segmentation d'images couleur par classification pixellaire et hiérarchie
de partitions THESE DOCTORAT de l'UNIVERSITE de CAEN/BASSE-NORMANDIE
CAEN avril 2002
- [15] J. MACQUEEN. « Some methods for classification and analysis of multivariate
observations ». Dans Berkeley Symposium on Mathematical Statistics and Probability, vol.
1, pages 281–297, 1967.
- [16] Hanifi Majdoulayne Extraction de caractéristiques de texture pour la classification
d'images satellites THÈSE DOCTORAT l'Université Toulouse III – Paul Sabatier novembre
2009
- [17] Pierre-Louis GONZALEZ « MÉTHODES DE CLASSIFICATION »
- [18] Zadeh L. A. "Fuzzy Sets", Inform. Control, 8, pp. 338-353, 1965.

Référence bibliographique

[19] E. R. Ruspini, "A New Approach to Clustering", Inform. Control, vol. 15, no. 1, pp. 22-32, July 1969.

[20] Lotfi KHODJA Contribution à la Classification Floue non Supervisée. le titre de DOCTEUR . THESE de L'UNIVERSITE DE SAVOIE

[21] 4th International Conference on Computer Integrated Manufacturing CIP'2007 03-04. Système Coopératif de Classification Floue Possibiliste avec Rejet d'Ambiguïté « Application à la segmentation d'images IRM » November 2007

[22] J Bezdek, "Pattern Recognition with Fuzzy Objective Function Algorithms", Plenum Press, New

York, 1981.

[23] Settouti Nesma .Renforcement de l'Apprentissage Structurel pour la Reconnaissance du Diabète UNIVERSITÉ ABOU BEKR BELKAID MAGISTER EN ÉLECTRONIQUE

Site internet

<http://www.uhrad.com>

[http://sante.lefigaro.fr/sante/organe/cerveau/quelles-sont-principales-maladies-cerveau\)](http://sante.lefigaro.fr/sante/organe/cerveau/quelles-sont-principales-maladies-cerveau)

[1] <http://www.med.harvard.edu/AANLIB/home.html>